

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky

BAKALÁŘSKÁ PRÁCE

2017

Veronika Vicianová

VŠB – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského
inženýrství

Extrakce objektů z medicínských obrazů na základě
metody aktivních kontur

Objects extraction from medical images based on the
active contour method

Zadání bakalářské práce

Student:

Veronika Vicianová

Studijní program:

B2649 Elektrotechnika

Studijní obor:

3901R039 Biomedicínský technik

Téma:

Extrakce objektů z medicínských obrazů na základě metody
aktivních kontur
Objects Extraction from Medical Images based on the Active
Contour Method

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Nastudování anatomie kolenní oblasti.
2. Nastudování anatomie a patologie kolenní chrupavky.
3. Nastudování metod, které se využívají pro zobrazování, a klinické hodnocení kolenní chrupavky.
4. Rešerše segmentačních metod kolenní chrupavky.
5. Předpracování MR dat kolenních chrupavek.
6. Implementace algoritmu aktivních kontur pro segmentaci kolenních chrupavek.
7. Analýza a vyhodnocení segmentačních výsledků.

Seznam doporučené odborné literatury:


- [1] DOUGHERTY, Geof. Image analysis in medical imaging: recent advances in selected examples. *Biomedical Imaging and Intervention Journal*. vol.6, iss.3, 2010. DOI:10.2349/bij.6.3.e32.
- [2] BEUTEL, Jacob, Harold L. KUNDEL a Richard L VAN METTER.(eds.) *Handbook of Medical Imaging*. vol. 1. Bellingham, Washington: SPIE Press. 2000. ISBN 0-8194-3621-6.
- [3] RANGAYYAN, Rangaraj M. *Biomedical Image Analysis*. Boca Raton: CRC Press, 2004. ISBN 978-0849396953.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí bakalářské práce: **Ing. Jan Kubiček**

Datum zadání: 01.09.2016

Datum odevzdání: 28.04.2017


doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry




prof. RNDr. Václav Snášel, CSc.
děkan fakulty

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

V Ostravě dne 28.4.2017

.....*Veronika*.....

Veronika Vicianová

Poděkování

Ráda bych tímto poděkovala svému vedoucímu bakalářské práce, panu Ing. Janu Kubičkovi, za odborné vedení, cenné připomínky a ochotu konzultovat průběžné i konečné výsledky.

Abstrakt

Tato bakalářská práce řeší problematiku extrakce artikulární chrupavky ze snímku kolenního kloubu pořízeného magnetickou rezonancí. Pro účely segmentace je použita poloautomatická metoda aktivních kontur, implementovaná v prostředí MATLAB. V práci je porovnávána efektivita použití základních metod předzpracování obrazu pro zlepšení výsledků segmentace aktivními konturami. Následná extrakce je řešena binarizací barevné mapy, která je jedním z výsledků segmentace. Extrahovaná plocha je následně validována manuální segmentací. Jedním z dílčích úkolů práce je ověření, zdali jsou aktivní kontury schopny detekovat počínající patologické stavy chrupavky. Metodu lze výhledově využít v diagnostice, při volumetrických měřeních nebo při tvorbě 3D modelů chrupavek.

Klíčová slova

Artikulární chrupavka, kolenní chrupavka, osteoartróza, magnetická rezonance, aktivní kontury, segmentace chrupavky, extrakce chrupavky

Abstract

This bachelor thesis is focused on the articular cartilage extraction from the knee image records acquired by the magnetic resonance (MR). A semi-automatic method based on the active contour is used for the segmentation purposes. The segmentation algorithm is implemented in the SW MATLAB. In the thesis, an effectivity of basic image preprocessing methods is compared with the aim of improving the segmentation results by the active contour model. The consequent extraction of articular cartilage is based on the binarization of the color map which represents one of the segmentation results. The extracted area is consequently validated on the base of the manual segmentation. One of the issue is the validation weather the active contour method is able to detect the early articular cartilage pathological changes. The method has ambitions to be used in the clinical practice in volumetric measurements, or 3D articular cartilage models.

Key words

Articular cartilage, knee cartilage, osteoarthritis, magnetic resonance, active contours, cartilage segmentation, cartilage extraction

Obsah

| | |
|--|----|
| Seznam použitých symbolů a zkratk | 8 |
| Seznam ilustrací | 9 |
| Seznam tabulek | 11 |
| 1 Úvod | 12 |
| 2 Anatomie kolenního kloubu | 13 |
| 2.1 Vazivový aparát kolenního kloubu | 14 |
| 2.2 Patella | 14 |
| 3 Chrupavka | 15 |
| 3.1 Artikulární chrupavka | 15 |
| 3.1.1 Stavba | 15 |
| 3.1.2 Struktura | 16 |
| 3.1.3 Patologie artikulární chrupavky | 17 |
| 4 Zobrazovací metody | 19 |
| 4.1 Rentgen | 19 |
| 4.2 Ultrazvuk | 19 |
| 4.3 Magnetická rezonance | 20 |
| 4.3.1 Sekvence magnetické rezonance | 20 |
| 5 Rešerše segmentačních metod pro oblast kolenní chrupavky | 23 |
| 5.1 Manuální segmentace | 23 |
| 5.2 Automatická segmentace | 24 |
| 5.2.1 Analýza textur | 24 |
| 5.2.2 Strojové učení | 25 |
| 5.2.3 Graph-cut | 26 |
| 5.3 Poloautomatická segmentace | 27 |
| 5.3.1 Segmentace založená na intenzitě | 27 |
| 5.3.2 Detekce hran | 28 |
| 5.3.3 Minimalizace energie | 29 |
| 5.4 Závěr | 30 |
| 6 Aktivní kontury | 31 |
| 6.1 Parametrické aktivní kontury | 31 |
| 6.1.1 Interní energie | 31 |

| | | |
|-------|---|----|
| 6.1.2 | Energie obrazu..... | 32 |
| 6.2 | Geometrické aktivní kontury..... | 33 |
| 6.2.1 | Level-set metoda | 33 |
| 6.2.2 | Aktivní kontury bez hran..... | 34 |
| 7 | Automatizovaná segmentace artikulární chrupavky | 35 |
| 7.1 | Předzpracování snímků | 35 |
| 7.1.1 | Vytvoření ROI..... | 36 |
| 7.1.2 | Jasová transformace | 36 |
| 7.1.3 | Interpolace | 37 |
| 7.2 | Implementace metody aktivních kontur | 39 |
| 7.2.1 | Matematický podklad metody | 39 |
| 7.2.2 | Umístění inicializační kontury | 41 |
| 7.3 | Testování algoritmu..... | 42 |
| 7.3.1 | Funkce activecontour()..... | 42 |
| 7.3.2 | Testování na nativních snímcích | 44 |
| 7.3.3 | Testování na ROI | 45 |
| 7.3.4 | Testování na ROI s interpolací..... | 46 |
| 7.3.5 | Testování snímků s jasovou transformací | 47 |
| 7.3.6 | Vliv umístění a tvaru inicializační kontury na segmentaci | 49 |
| 7.3.7 | Analýza výpočetní náročnosti funkce | 50 |
| 7.3.8 | Testování algoritmu na jiných sekvencích | 53 |
| 8 | Validace manuální segmentací..... | 54 |
| 8.1 | Nativní snímky | 55 |
| 8.2 | ROI..... | 56 |
| 8.3 | ROI po interpolaci..... | 57 |
| 8.4 | Snímky po jasové transformaci | 58 |
| 8.4.1 | Nativní snímky po jasové transformaci..... | 58 |
| 8.4.2 | ROI po jasové transformaci..... | 59 |
| 8.4.3 | ROI po interpolaci a jasové transformaci..... | 60 |
| 8.5 | Shrnutí | 61 |
| 9 | Závěr | 62 |
| | Seznam literatury | 64 |
| | Seznam příloh..... | 68 |

Seznam použitých symbolů a zkratek

| | |
|-----------------|---|
| 3D | trojrozměrný |
| CT | počítačová tomografie |
| E | energie [J] |
| GAG | glykosaminoglykany |
| GRE | gradientní echo |
| GVF | gradientní vektorový tok |
| H(x) | Heavisideova funkce |
| MHz | megahertz, jednotka frekvence |
| MR | magnetická rezonance |
| MRI | zobrazování magnetickou rezonancí |
| Na ⁺ | kationt sodíku |
| Obr. | obrázek |
| PD | proton denzní |
| ROI | oblast zájmu (angl. <i>region of interest</i>) |
| SNR | poměr signál-šum |
| SE | spinové echo |
| T | Tesla, jednotka magnetické indukce |
| T1 | podélná relaxace |
| T2 | příčná relaxace |
| Tab. | tabulka |
| TE | čas signálu echa |
| TR | repetiční čas |
| a. | tepna |
| angl. | anglicky |
| cm | centimetry |
| kNN | k-nejbližší soused |
| m. | sval |
| ml | mililitry |
| px | pixel, obrazový bod |
| n. | nerv |
| s | sekunda |
| tzv. | takzvaný |
| ° | stupeň |
| °C | stupeň Celsia |
| ∇ | gradient |
| ∇^2 | Laplaceův operátor |
| % | procenta |

Seznam ilustrací

| | |
|---|----|
| Obr. 2.1 – Anatomie kolenního kloubu [2] | 13 |
| Obr. 3.1 – Struktura artikulární chrupavky [5]..... | 16 |
| Obr. 3.2 – Stádia patologických změn artikulární chrupavky [8] | 18 |
| Obr. 4.1 – Rentgenový snímek kolena; vlevo: předozadní snímek, vpravo: boční snímek [10]..... | 19 |
| Obr. 4.2 – Ultrazvukový snímek chrupavky femuru [10] | 19 |
| Obr. 4.3 – Sagitální 2D fast SE zobrazení artikulární chrupavky, šipky označují lokální defekt [15] . | 20 |
| Obr. 4.4 – 3D sekvence MR [15] | 21 |
| Obr. 5.1 – MR zobrazení kolenního kloubu a manuální segmentace tibiální chrupavky [16] | 23 |
| Obr. 5.2 – MR zobrazení kolenního kloubu a manuální segmentace patellární chrupavky [16] | 23 |
| Obr. 5.3 – Segmentace analýzou textur [18] | 25 |
| Obr. 5.4 – Segmentace artikulární chrupavky metodou strojového učení [19] | 26 |
| Obr. 5.5 – Segmentace artikulární chrupavky metodou LOGISMOS [20] | 26 |
| Obr. 5.6 – Segmentace rozvodím [23] | 28 |
| Obr. 5.7 – Segmentace artikulární chrupavky poloautomatickým softwarem J. Duryea [25] | 29 |
| Obr. 5.8 – Syntetický obraz MR; a) tibiální chrupavka; b) femorální chrupavka [27] | 30 |
| Obr. 7.1 – Vývojový diagram obecného postupu segmentace aktivními konturami | 35 |
| Obr. 7.2 – Vývojový diagram předzpracování snímků | 35 |
| Obr. 7.3 – Porovnání nativního snímku (vlevo) a extrahovaného ROI (vpravo) | 36 |
| Obr. 7.4 – Graf jasové transformace použité pro snímky z datasetu..... | 36 |
| Obr. 7.5 – Snímek kolene před (vlevo) a po (vpravo) jasové transformaci | 37 |
| Obr. 7.6 – Oblast přiblížení snímku bez interpolace (vlevo) a s interpolací (vpravo) | 38 |
| Obr. 7.7 – Graf závislosti výpočetní náročnosti na zvoleném stupni interpolace | 38 |
| Obr. 7.8 – Vývojový diagram implementované metody | 39 |
| Obr. 7.9 – Evoluce křivky od inicializační kontury po finální konturu, počet iterací = 850..... | 41 |
| Obr. 7.10 – Segmentace chrupavky funkcí activecontour() s hranovou detekcí | 42 |
| Obr. 7.11 – Zkouška detekce osteoartrózy funkcí activecontour() s hranovou detekcí | 43 |
| Obr. 7.12 – Segmentace chrupavky funkcí activecontour() bez hranové detekce | 43 |
| Obr. 7.13 – Testování metody na nativních snímcích | 44 |
| Obr. 7.14 – Testování metody na ROI | 45 |
| Obr. 7.15 – Testování metody na ROI s interpolací | 46 |
| Obr. 7.16 – Testování metody na nativních snímcích po jasové transformaci..... | 47 |
| Obr. 7.17 – Testování metody na ROI po jasové transformaci | 48 |
| Obr. 7.18 – Testování metody na ROI po jasové transformaci a interpolaci | 48 |
| Obr. 7.19 – Nevhodné umístění inicializační kontury..... | 49 |
| Obr. 7.20 – Správně zvolené umístění inicializační kontury | 49 |
| Obr. 7.21 – Segmentace chrupavky za použití inicializace kružnicí..... | 50 |
| Obr. 7.22 – Závislost výpočetní náročnosti pro nativní snímky | 51 |
| Obr. 7.23 – Závislost výpočetní náročnosti pro ROI | 51 |
| Obr. 7.24 – Závislost výpočetní náročnosti pro ROI po interpolaci | 52 |
| Obr. 7.25 – Testování metody na sekvenci rychlé spinové echo, T1 vážený obraz [8] | 53 |
| Obr. 7.26 – Testování metody na sekvenci 3D gradientní echo [12] | 53 |

| | |
|---|----|
| Obr. 7.27 – Testování metody na sekvenci rychlé spinové echo, proton-denzní obraz, bez potlačení tuku [8]..... | 53 |
| Obr. 8.1 – Průběh a výsledek manuální segmentace artikulární chrupavky | 54 |
| Obr. 8.2 – Porovnání automatické (vlevo) a manuální (vpravo) segmentace artikulární chrupavky | 54 |
| Obr. 8.3 – Průměrný procentuální rozdíl jednotlivých testovaných skupin | 61 |

Seznam tabulek

| | |
|--|----|
| Tab. 1 – Porovnání segmentovaných ploch chrupavek z nativních snímků..... | 55 |
| Tab. 2 – Porovnání segmentovaných ploch chrupavek z ROI | 56 |
| Tab. 3 – Porovnání segmentovaných ploch chrupavek z interpolovaných ROI | 57 |
| Tab. 4 – Porovnání segmentovaných ploch chrupavek z nativních snímků po jasové transformaci | 58 |
| Tab. 5 – Porovnání segmentovaných ploch chrupavek z ROI po jasové transformaci | 59 |
| Tab. 6 – Porovnání segmentovaných ploch chrupavek z interpolovaných ROI po jasové transformaci | 60 |

1 Úvod

Defekty artikulární chrupavky kolenního kloubu trápí značnou část populace. Chrupavka má tendenci se s přibývajícím věkem opotřebovávat a je více náchylná pro vznik osteoartrózy a jiných degenerativních onemocnění. Problémy s artikulární chrupavkou ovšem nejsou jen záležitost starší generace. Mnoho mladých lidí (například vrcholových sportovců) je nuceno čelit podobným problémům. Ty mohou vzniknout jako následek zranění či neustálého přetěžování kolenní chrupavky a nedostatečné regenerace. Chrupavka má velmi pomalou schopnost vlastní regenerace, a proto je včasná diagnostika jejího poškození klíčová pro úspěšnou a kratší léčbu. Úkolem tohoto softwaru je segmentace a následná extrakce oblasti artikulární chrupavky kolene za účelem zjištění jejího poškození již v raném stádiu nemoci, kdy je pouhým okem špatně rozpoznatelné, a tím pomoci při včasné diagnostice onemocnění. Z důvodu absence automatických a poloautomatických softwarových metod pro segmentaci chrupavky v klinické praxi je jejich vývoj důležitý pro usnadnění práce kliniků, snížení časové náročnosti a zkvalitnění výsledků detekce patologických stavů.

2 Anatomie kolenního kloubu


Kolenní kloub je nejsložitějším kloubem v lidském těle. Jedná se o kloub složený a spojuje navzájem tři kosti: femur, tibia, a patellu. Mezi styčné plochy femuru a tibie jsou vloženy kloubní menisky, tvořené vazivovou chrupavkou. Hlavní funkcí kolenního kloubu je pohyb dolní končetiny. [1]

Styčné plochy kloubu jsou: condyli femoris, facies articularis superior, facies articularis patellae a facies patellaris femoris. Kontakt mezi femurem a tibií je prakticky v horizontální rovině. Menisky jsou vazivové ploténky, lišící se velikostí a tvarem. Na vnějším obvodu jsou vyšší než na vnitřním. Cípy se upínají na tibia a jejich obvod je připojen ke kloubnímu pouzdru. [1]

Základní postavení je plná extenze, kdy jsou napjaty postranní vazy a femur, menisky a tibia na sebe vzájemně naléhají. Základním pohybem kolenního kloubu je flexe a následně zpětná extenze. Rozsah flexe kolenního kloubu je 130–160 °. Extenze by u zdravého kloubu neměla přesáhnout více než 15 °. Tato skutečnost je zajištěna tahem kolaterálních vazů. Při flexi se patella pohybuje distálním směrem, při extenzi proximálním. Vnitřní a zevní rotace je umožněna pouze při současné flexi kloubu a probíhá v meniskotibiálním skloubení za současného posunu menisků. [1]

Cévní zásobení kolena je zajištěno větvemi a. femoralis a a. poplitea. Inervace je prostřednictvím větví z n. femoralis, n. tibialis a n. fibularis communis. [1]

Kloubní pouzdro kryje povrch kloubu, je tvořeno vazivovou tkání a jeho funkce je zvyšovat stabilitu kolena a zabránit abnormálním pohybům. Na femuru se upíná dále od kloubních ploch, dále se vyklenuje nad patellu (pod m. quadriceps femoris) a upíná se na tibia při okraji kloubní plochy. [1]



Obr. 2.1 – Anatomie kolenního kloubu [2]

2.1 Vazivový aparát kolenního kloubu

Je tvořen ligamenty kloubního pouzdra a nitrokloubními ligamenty: [1]

Ligamenta kloubního pouzdra:

1. Ligamentum patellae – jedná se o pokračování šlachy m. quadriceps femoris přes hrot pately až na tuberositas tibiae.
2. Reticula patellae – podobně jako předchozí vychází z m. quadriceps femoris a upíná se na tibií, ale probíhá po obou stranách patelly.
3. Ligamentum collaterale tibiale et fibulare – jdou od epikondylů femuru a upínají se na tibií nebo na fibulu.

Nitrokloubní ligamenta:

1. Ligamenta cruciata genus – spojují femur s tibií. Napínají se při ohnutí kolena a zajišťují jeho pevnost.
2. Ligamentum transversum genus – propojuje napříč menisky.
3. Ligamentum meniscofemorale posterius a anterius – spojují femur a laterální meniskus.

2.2 Patella

Patella je největší sezamská kost v lidském těle. Leží v úponové šlaše m. quadriceps femoris. Chrupavka patelly je nejsilnější v celém těle. Její tvar je u každého člověka jedinečný, což může být ale zdrojem různých obtíží. Patella má několik funkcí: spojuje 4 šlachy m. quadriceps femoris, reguluje napětí kloubního pouzdra, chrání kolenní kloub před nárazy a údery, má elastickou úlohu v kolenním kloubu, snižuje tření na kondylech femuru. [3]

Patella je vystavena největšímu tlaku při kontrakci m. quadriceps femoris. Nejvyšší tlak je vyvíjen na laterální straně skloubení, přičemž se začíná vyvíjet od 10° flexe. S navyšováním stupňů se zvyšuje také tlak na patellu. Síla vyvíjená ve femoropatellárním kloubu je při běžném pohybu do trojnásobku váhy těla. Při fyzické námaze, dřepch, chůzi po schodech apod. může dosáhnout až osminásobku váhy těla. [3]

3 Chrupavka

Chrupavka je pojivová tkáň vzniklá z mezenchymu. Obecně je chrupavka složena z chondrocytů a mezibuněčné hmoty. Chondrocyty jsou oválné buňky, jejichž hlavním úkolem je vytvářet mezibuněčnou hmotu a udržovat její stabilitu. Tu rozdělujeme na vláknitou a amorfní. Amorfní složku mezibuněčné hmoty tvoří převážně glykosaminoglykany (kyselina hyaluronová, keratansulfát, chondroitinsulfát), proteoglykany a strukturální proteiny. Fibrilární složka je tvořena vlákny kolagenu. [3][4]

Povrch chrupavek je tvořen perichondriem, což je vazivový obal sloužící k látkové výměně a inervaci chrupavky. U artikulárních chrupavek perichondrium chybí a povrch je kryt tzv. chondrální membránou, tvořenou polysacharidy, která svým lubrikačním efektem snižuje tření. Látková výměna je zajištěna jednak difuzí ze synoviální tekutiny kloubu, a jednak ze subchondrálních cév. Samotná chrupavka neobsahuje žádné cévy ani není nijak inervována. Mezi hlavní funkce chrupavek patří podpora měkkých tkání, tlumení nárazů, klouzavý pohyb kostí při pohybu a v neposlední řadě růst a vývoj kostí. [3]

Pro chrupavku je typická nízká koncentrace kyslíku a anaerobní metabolismus. Pomalý metabolismus je příčinou zpomalení reparačních procesů ve chrupavce a proto každé její poškození se hojí několik měsíců. [3]

Podle složení mezibuněčné hmoty dělíme chrupavky na vazivové, elastické a hyalinní. Elastická chrupavka je velice pružná a ohebná, je nažloutlé barvy, obsahuje četné fibrily a tvoří stěny průdušek, ušní boltec nebo například hrtanovou přiklopku. Vazivová chrupavka obsahuje silné svazky vazivových vláken a málo chondrocytů. Je mechanicky odolná a tvoří především meziobratlové destičky nebo sponu stydkou. Hyalinní (sklovitá) chrupavka je poloprůhledná, namodralá a pokrývá kloubní hlavice, tvoří konce žeber nebo také chrupavčitý podklad nosu. [3]

3.1 Artikulární chrupavka

Artikulární chrupavka je tvořena hyalinní chrupavkou. Vytváří povlak kloubních hlavic, jejichž tvar kopíruje, ale není na všech místech stejně silná. Její tloušťka závisí na míře zatížení a na nerovnosti kloubních ploch. Nejsilnější vrstva artikulární chrupavky se nachází na česce v kolenním kloubu. [3]

3.1.1 Stavba

Artikulární chrupavku tvoří méně než 10 % chondrocytů a kolagenní vlákna. Vlákna jsou uspořádána do sítě a jejich hlavní funkcí je udávání tvaru a zajištění pevnosti chrupavky. Majoritní zastoupení mají kolagenní vlákna typu II (více než 80 %). Dále se vyskytuje kolagen typu IX, odpovědný za ukotvení proteoglykanů v síti, a kolagen typu VI, který zabezpečuje mechanickou ochranu chondrocytů. Dále chrupavka obsahuje makromolekuly – proteoglykany a glykoproteiny. [3]

Proteoglykany se skládají z 90 % ze sacharidové složky a z 10 % z proteinů. Jsou to vysoce hydrofilní molekuly – mají schopnost vázat vodu. Mimo jiné fungují také jako tzv. „molekulární síta“. Sacharidovou složku tvoří glykosaminoglykany (GAG). Podle velikosti dělíme proteoglykany na agrekany a proteoglykanové agregáty. Agrekany se skládají z osového proteinu, na který jsou navázány GAG. Proteoglykanové agregáty se skládají z agrekanů navázaných na řetězec kyseliny hyaluronové.


Kyselina hyaluronová se vyskytuje také volně v synoviální tekutině, kde zajišťuje viskoelasticitu a přispívá ke stabilitě vnitřního prostředí. [3][4]

Glykoproteiny jsou bílkoviny, na něž jsou kovalentně navázány oligosacharidové řetězce. Platí, že proteinová složka převažuje nad sacharidovou. Mezi jejich zástupce patří fibronektin a chondronektin. Jejich funkce je zvýšení přilnavosti chondrocytů ke kolagenu matrix. [3][4]

Dále chrupavku tvoří tkáňový roztok, který je složen z vody, plynů, ostatních malých proteinů a metabolitů. Obsah tekutiny ve chrupavce je důležitý, protože udává její pružnost a tvar. Kloubní chrupavka navazuje na synoviální membránu kloubního pouzdra, které produkuje synoviální tekutinu. Obsah synoviální tekutiny v kolenním kloubu je fyziologický do objemu 4 ml. [3][4]

3.1.2 Struktura

Chrupavka je do hloubky tvořena několika vrstvami (zónami), přičemž každá má své charakteristické vlastnosti. Jednotlivé zóny se navzájem prolínají: [4][5][6]



Obr. 3.1 – Struktura artikulární chrupavky [5]

Povrchová zóna:

Tato vrstva je ze všech nejtenčí. Na povrchu jsou fibrily pokryté synoviální vrstvou za účelem snížení třecích sil. Jejich funkce je zamezit přímému kontaktu chondrocytů s kloubním povrchem. Pod touto vrstvou jsou paralelně uspořádány elipsoidní chondrocyty, čímž je zajištěna síla v tahu. Chondrocyty produkují více kolagenních vláken a méně proteoglykanů. Mezibuněčná hmota obsahuje v této vrstvě nejvíce vody. Tato vrstva mimo jiné funguje také jako filtr proti velkým makromolekulám a tedy se podílí na imunitním systému chrupavky.

Přechodná zóna:

Tato vrstva obsahuje větší kolagenní vlákna, které zde svou polohou přecházejí z paralelního uspořádání do sloupcového, které je typické pro následující vrstvu. Uspořádání je tedy náhodné a obloukové. Toto uspořádání zajišťuje odolnost v tlaku. Dále obsahuje více proteoglykanů, ale méně kolagenních vláken a vody než předcházející vrstva. Chondrocyty mají sférický tvar a oproti předchozí vrstvě obsahují organely jako endoplasmatické retikulum, Golgiho aparát nebo mitochondrie.

Radiální zóna:

Tato vrstva je obvykle největší, obsahuje největší koncentraci proteoglykanů a agrekanů a nejméně vody. Její kolagenní vlákna jsou nejdelší a uspořádané radiálně ke kloubnímu povrchu. Chondrocyty vykazují obrovskou syntetickou a metabolickou aktivitu.

Kalcifikovaná zóna:

Hranice mezi touto vrstvou a subchondrální kostí je nejasná. Zde dochází ke kalcifikaci chrupavky, vlákna přecházejí kolmo do kosti a chrupavka volně přechází v kost. Chondrocyty jsou menší s nízkou metabolickou aktivitou.

3.1.3 Patologie artikulární chrupavky

3.1.3.1 Osteoartróza

Je to nejčastější onemocnění kloubní chrupavky a jejích okolních tkání. Osteoartróza je charakteristická svými metabolickými změnami v matrix, defekty na povrchu chrupavky a v pozdějším stádiu může být provázena zánětem. Chrupavka se stává ztenčenou a rozvlákněnou. [3]

Epidemiologie:

Postihuje asi 15 % populace. Pravděpodobnost výskytu stoupá s věkem. Udává se, že ve věku nad 65 let postihuje zhruba 50 % populace a nad 75 let až 85 % populace. [3]

Příčiny:

Podle příčin dělíme osteoartrózu na primární a sekundární: [3][7]

1. Primární neboli idiopatická je taková, kde není jasná příčina. Mezi rizikové faktory se řadí věk, obezita, genetické dispozice aj.
2. U sekundární je příčina známá, může se jednat o příčiny, jako jsou například traumata a mikrotraumata, trvalé přetížení vysoké intenzity, kongenitální a vývojové vady, metabolické nemoci, endokrinní choroby, jiné mechanické faktory a zánětlivá onemocnění.

Patogeneze:

Pozorujeme mikroskopické a později i makroskopické změny:

1. Mikroskopické změny:

Při onemocnění dochází k nerovnováze metabolických aktivit chondrocytů. Při osteoartróze dochází prvotně k biodegradaci složek mezibuněčné matrix chrupavky, na níž reagují chondrocyty zvýšením své aktivity ve snaze kompenzovat defekty v matrix. Změny probíhají na různých místech chrupavky a nastává nerovnováha. Klesá množství kyseliny hyaluronové, což vede ke zhoršení kvality synoviální tekutiny. Ta ztrácí svou viskozitu a schopnost lubrikace. Také je při pokročilém stádiu zvýšená apoptóza (buněčná smrt) buněk ze 4,8 % chondrocytů na 22 %. Ubývá také množství kolagenu a naopak se zvyšuje koncentrace fibronektinu. [3][7]

2. Makroskopické změny:


V důsledku biochemických změn dochází ke změknutí chrupavky, k jejímu zmatnění a rozvláknění. Je omezena vazebnost pro vodu a chrupavka se stává nepružnou a méně odolnou vůči mechanické zátěži. Dochází k mikrofrakturám subchondrální kosti a k tvorbě cyst. Dále dochází ke změnám synovie a kloubního pouzdra. V pozdějším stádiu může být problémem synovitida, která je téměř nerozlišitelná od revmatoidní artritidy. [3][7]

Klinické příznaky:

Mezi příznaky patří v raném stádiu bolest v kloubu na začátku pohybu, která se po rozehýbání zmírní. S rozvojem se objevuje bolest při pohybu nebo ponámahová, v nejpokročilejším stádiu také bolest klidová. Mezi další příznaky patří ztuhlost kloubů, která trvá 10–15 minut od počátku pohybu. Při klinickém vyšetření lze vidět různá forma deformace kloubu, menší rozsah pohybu a bolest v krajních mezích rozsahu. Dále lze pozorovat změnu osového postavení. Pokud je součástí onemocnění synovitida, pozorujeme otok měkkých tkání a kloubní výpotek. [3][7]

Podle rozsahu makroskopického poškození zavedl Outerbridge klasifikaci patologických stavů artikulární chrupavky: [3]

- 1. stupeň:** ložisko do 0,5 cm v průměru, edém, měkká konzistence chrupavky, matný a nažloutlý povrch
- 2. stupeň:** fibrilace a trhliny na ploše o průměru do 1,5 cm
- 3. stupeň:** fibrilace a trhliny na ploše o průměru větším než 1,5 cm
- 4. stupeň:** defekt na subchondrální kosti



Obr. 3.2 – Stádia patologických změn artikulární chrupavky [8]

4 Zobrazovací metody

Artikulární chrupavku je v dnešní době možné zobrazit neinvazivně rentgenem, ultrazvukem a magnetickou rezonancí. Mezi invazivní metody patří např. artroskopie.

4.1 Rentgen


Skiografie je častou metodou pro zobrazení kloubní chrupavky. Hyalinní chrupavka ovšem není na rentgenu přímo viditelná, proto její stav hodnotíme pouze nepřímo dle šíře kloubní štěrbiny, což ale může být ovlivněno tekutinou v kloubu nebo zánětlivě zesílenou synoviální výstelkou. Měření kloubní štěrbiny by se mělo provádět v nejužším místě a v plné zátěži vahou těla. Obecně jsou ale tato měření nepřesná a zatížena velkou chybou. Rozhodující může být subjektivnost hodnocení různými lékaři. Dále jsou na rentgenovém zobrazení dobře viditelné osteofyty a osifikace okolních tkání. [9]



Obr. 4.1 – Rentgenový snímek kolena; vlevo: předozadní snímek, vpravo: boční snímek [10]

4.2 Ultrazvuk

Obecně je ultrazvuk používán málo a je méně citlivý než zobrazení pomocí MR. Ultrazvuk se používá k odhalení kalcifikací v kloubu. Stav chrupavky lze posoudit dle změny její echogenity, při hyperechogenitě je v chrupavce obsaženo méně vody. [9]



Obr. 4.2 – Ultrazukový snímek chrupavky femuru [10]

Na Obr. 4.2 je znázorněna chrupavka femuru, na levé straně je zdravá chrupavka a na pravé straně je patologická. Šipka označuje oblast chondropatie.

4.3 Magnetická rezonance

Magnetická rezonance je nejčastější metodou využívanou pro vyšetření artikulárních chrupavek. Její výhodou je oproti jiným zobrazovacím metodám téměř perfektní rozlišení měkkých tkání a její neinvazivnost. Nevýhodou může být delší doba vyšetření a poměrná hlučnost.

Vyšetřením kolena pomocí magnetické rezonance je možné zjistit případné defekty na artikulární chrupavce, sledovat průběh případného onemocnění, případně zhodnotit efektivitu probíhající léčby.

K zobrazování chrupavčitých tkání se v dnešní době používají různé sekvence. Nejčastěji je využívána sekvence rychlé spinové echo a současně proton-denzní zobrazení, které zobrazuje hustotu protonů na jednotku objemu. Dále se také hojně využívá metod pro potlačení signálu tuku. Pro diagnostické účely je často důležité zobrazit kloub ve více rovinách. [11][12]

4.3.1 Sekvence magnetické rezonance

Hlavním cílem MR zobrazování je vytvořit snímek s kontrastem mezi jednotlivými typy tkání. Jas je ovlivněn několika faktory: T1 relaxace, T2 relaxace a PD (protonová hustota).

Vhodným uspořádáním pulsní sekvence můžeme dosáhnout požadovaného kontrastu: [13][14]

- **T1-vážený obraz** – dobře zobrazuje strukturu chrupavky, ale poskytuje špatný kontrast mezi kloubní tekutinou a povrchem chrupavky. Také špatně zobrazuje další struktury v kolenu například vazy. Příklad tohoto zobrazení je na Obr. 4.3 vlevo.
- **T2-vážený obraz** – poskytuje dobrý kontrast mezi povrchem chrupavky a kloubní tekutinou, ale je oslaben signál zevnitř chrupavky (Obr. 4.3 uprostřed).
- **PD-vážený obraz** – je schopen dobře zobrazit jak kontrast mezi chrupavkou a synoviální tekutinou tak vnitřní strukturu chrupavky. Zobrazení je znázorněno na Obr. 4.3 vpravo.



Obr. 4.3 – Sagitální 2D fast SE zobrazení artikulární chrupavky, šipky označují lokální defekt [15]


Změna kontrastu souvisí se změnou pulsní sekvence. U té se udávají tři hlavní parametry: [14]

- **sklápěcí úhel α** – energie použitá na radiofrekvenční excitační puls (čím více energie vyzáříme, tím delší je čas pro plnou relaxaci)

- **čas TR (repetiční čas)** – udává dobu, po níž opakovaně aplikujeme excitační pulsy, čím kratší je TR, tím kratší je T1 relaxace
- **čas TE (čas signálu echa, echo čas)** – čas mezi excitačním pulsem a detekcí rezonančního signálu – při delším času TE budou jádra s kratším časem T2 přispívat k měřenému signálu méně

Pro zjištění morfologie chrupavky jsou v dnešní době nejčastěji využívány sekvence:

- **Spinové echo (SE)** – Spinové echo je tvořeno párem radiofrekvenčních pulzů se sklápěcím úhlem 90° a 180° . Dnes se využívá pouze k vytvoření T1-vážených obrazů, protože tyto obrazy využívají krátké TR v rozmezí zhruba 450–700 ms, takže celkový čas měření je akceptovatelný. TE se pokoušíme zvolit co nejkratší, udává se rozmezí mezi 8–15 ms. [13]
- **Gradientní echo (GRE)** – vznikne aplikací dvojice gradientních pulzů po jednom excitačním radiofrekvenčním pulzu, který má obvykle sklápěcí úhel alfa v rozmezí 10° – 70° . Lze zvolit kratší čas TR a tím zkrátit čas měření. Signál je vždy ovlivněn nehomogenitou magnetického pole. [13]
- **Rychlé spinové echo** – je rychlejší variantou SE s použitím vícečetných spinových ech. Echa reprezentují vždy jeden řádek matice dat. Pokud při jednom TR nabereme n řádků, měření je urychleno n-krát. Přínos rychlého SE je znatelný při použití dlouhého TR, tedy u T2-vážených obrazů nebo u proton-denzitně vážených obrazů. Tato sekvence je jedna z nejčastěji využívaných při zobrazování artikulární chrupavky. [13]
- **3D SE a GRE**
 - 3D GRE poskytuje vyšší prostorové rozlišení a zlepšuje kvalitu zobrazení artikulární chrupavky v koleni, ale není ideální pro zobrazení subchondrální kosti. [11]
 - 3D fast SE poskytuje vysoko-kontrastní rozlišení a dobré prostorové rozlišení redukuje rozmazání a snižuje čas pořízení obrazu. Tato sekvence také na rozdíl od předchozí dobře zobrazuje abnormality na subchondrální kosti. V dnešní době tyto sekvence nejsou přes své kvality mnoho využívány, avšak mohou být dobrými vyhlídkami do budoucna. [11]



Obr. 4.4 – 3D sekvence MR [15]

Na Obr. 4.4 je znázorněn v levé části koronální 3D fast SE obraz a v pravé části sagitální 3D GRE T1-vážený obraz.

Při zobrazování artikulární chrupavky je běžně vyžadováno metod potlačení signálu tuku. Nejčastěji využívanou metodou je saturace tuku. [13]

Saturace tuku

Pomocí této metody jsme schopni zlepšit kvalitu obrazu v oblastech s vysokým množstvím tukové tkáně. Může být využívána s kteroukoli sekvencí magnetické rezonance. Metoda saturace tuku je aplikována ještě před zahájením samotné sekvence. Principem metody je vysílání krátkých radiofrekvenčních excitačních pulsů naladěných na rezonanční frekvenci tuků. Částice tuku jsou excitovány a následně použitím gradientu defázovány. [13]


5 Rešerše segmentačních metod pro oblast kolenní chrupavky

Segmentace artikulárních chrupavek umožňuje kvantitativní a kvalitativní analýzu morfologické struktury artikulární chrupavky. Cílem této rešerše je poskytnout informace o úskalích spojených se segmentací kolenní chrupavky a sumarizovat esenciální poznatky segmentačních metod aplikovaných na artikulární chrupavky, které byly publikovány v odborné literatuře. [17]


Existují tři typy segmentace: manuální, automatická a poloautomatická. Manuální segmentace spočívá v označení segmentované oblasti klinickým lékařem. Je časově nejnáročnější, ale přesto je to v dnešní době nejčastěji využívaná metoda. Poloautomatická segmentace je obvykle realizována prostřednictvím softwaru, který vyžaduje zásah uživatele, tím je většinou inicializace počáteční křivky nebo bodů. Automatická segmentace nevyžaduje vůbec žádný zásah uživatele a software pracuje zcela samostatně. [17]

5.1 Manuální segmentace

Manuální segmentace je i v dnešní době jedna z nejčastěji využívaných technik. Její nevýhodou je především časová náročnost. U segmentace kolenní chrupavky může tento proces trvat i několik hodin – v závislosti na velikosti obrazu, jeho kvalitě a fázi onemocnění pacienta. Navíc je tato metoda velmi ovlivněna lidským faktorem a tedy vyžaduje speciální zaškolení a praxi. Nicméně, automatické a poloautomatické softwary jsou často nedokonalé, a proto se tato metoda stále hojně využívá i přes svou náročnost. [17]



Obr. 5.1 – MR zobrazení kolenního kloubu a manuální segmentace tibiální chrupavky [16]



Obr. 5.2 – MR zobrazení kolenního kloubu a manuální segmentace patellární chrupavky [16]

5.2 Automatická segmentace

Z hlediska praktické využitelnosti je vždy vyžadována balance mezi přesností, robustností a mírou intervence uživatele. Ideální algoritmus by tedy byl maximálně precizní a přesný pro všechny typy obrazů a zároveň by měl vyžadovat minimální zásah uživatele. Nicméně tento požadavek znesnadňuje mnoho faktorů. [17]

Za prvé, chrupavčitá vrstva je velmi tenká, především u pacientů s osteoartrózou. Proto jsou potřeba obrazy s vysokým rozlišením, které ovšem mají delší akviziciční dobu. Tím vzniká další riziko, které tkví v mikropohybech pacienta a vzniku artefaktů. [17]

Dalším problémem je nízká úroveň kontrastu mezi chrupavkou a měkkými tkáněmi. Algoritmus proto musí být několikrát testován, aby byl schopen tyto prvky od sebe kvalitně rozpoznat. V neposlední řadě segmentaci znesnadňuje také šum obrazu, neboť se předpokládá, že obecná efektivita segmentačního algoritmu je závislá na kvalitě nativních obrazových dat. [17]

Sestavení takového softwaru tedy může být problém především, co se týče přizpůsobení různému typu dat. Proto není neobvyklé využívání plně-automatizovaného softwaru a poloautomatizovaného softwaru současně. [17]

Automatické segmentace lze rozdělit na:

1. Analýzu textur
2. Strojové učení (použití kNN klasifikátoru)
3. Graph-cut


5.2.1 Analýza textur

Ve článku [18] je rozhraní chrupavka-kost detekováno automatickou metodou. Algoritmus určený k segmentaci kosti se skládá z generátoru paprsku, tzv. vzorkovače a analyzátoru. Generátor vytváří směry z daného bodu, které mohou být nastaveny několika způsoby (cirkulárně, sféricky, paralelně apod.). Vzorkovač čte intenzity voxelů podél paprsku, případně aplikuje rozmazání obrazu, pokud je to nutné. Analyzátor poté určí, zdali vzorkovač narazil při sběru dat na kritéria hledání. Po nalezení kontury rozhraní chrupavka-kost je sestavena matice intenzit podél normál této kontury.

Autoři rozlišují dva znaky tkáňové textury: jas a homogenitu. Tmavé a světlé tkáně jsou rozděleny Otsu prahováním. Světlé oblasti jsou poté znovu prahovány na základě homogenity tkáně. Pomocí Otsu prahování je možné také separovat synoviální tekutinu od chrupavky, protože tekutina je více homogenní. Vnější hranice chrupavky je vyhodnocena hledáním hran podél normál.

Metoda byla porovnávána s poloautomatickou metodou [27] a testování proběhlo úspěšně. Systém byl uznán za spolehlivý a poskytující kvalitní hodnocení objemu chrupavky u pacientů s osteoartrózou.

Na Obr. 5.3 vidíme segmentaci analýzou textur. Vlevo je mediální zobrazení, vpravo je laterální zobrazení. Segmentované části jsou zobrazeny světle šedou barvou pro chrupavku femuru a tmavší šedou pro chrupavku tibie.



Obr. 5.3 – Segmentace analýzou textur [18]


5.2.2 Strojové učení

Folkesson ve článku [19] popisuje metodu založenou na tzv. kNN klasifikátoru (k-nearest neighbors). Algoritmus se skládá ze dvou binárních klasifikátorů (zvlášť pro tibiální a zvlášť pro femorální chrupavku). Klasifikátory jsou nastaveny speciálně pro typ chrupavky, kterou budou segmentovat. Autoři udávají, že $k = 100$ je ideální hodnota parametru, který je uživatelem definovanou konstantou, která udává počet sousedních voxelů. Podle toho, které voxely převažují z k -vybraných je poté daný voxel klasifikován.

Nejprve jsou klasifikovány voxely s nízkou hodnotou, umístěné přímo v centru datasetu. Pokud je voxel označen jako chrupavka, algoritmus postupuje ke klasifikaci vedlejšího voxelu. Proces je opakován, dokud nezůstává žádný sousední voxel označený jako chrupavka. Výsledné propojené komponenty jsou poté spojeny, aby vznikl jeden celkový komponent pro každou chrupavku. Vzhledem k nespojitosti kolenních struktur v obrazu je nutné jeho post-zpracování.

Software má dle testování vysokou přesnost a shodu s manuální segmentací. Byl testován na 139 snímcích, obsahujících jak kolenní klouby zdravých pacientů, tak pacientů s osteoartrózou. Je odolný vůči posunu během skenování. Nicméně software funguje spolehlivě pouze při použití nízkého magnetického pole při skenování magnetickou rezonancí.

Na Obr. 5.4 je vidět srovnání manuální segmentace (vlevo) s algoritmem Folkessona bez post-zpracování (uprostřed) a po post-zpracování (vpravo).




Obr. 5.4 – Segmentace artikulární chrupavky metodou strojového učení [19]

5.2.3 Graph-cut

Yin ve článku [20] představuje metodu zvanou LOGISMOS. Tato metoda vyžaduje hrubou před-segmentaci kostí. Nejprve je nalezena oblast zájmu každé kosti užitím Adaboost metody. Kostí jsou následně extrahovány z oblasti zájmu užitím součástí, jako jsou intenzity, gradienty a derivace druhého typu po Gaussově rozmazání. Tyto hrubé kostní segmenty jsou následně upraveny jednovrstevnatým grafem a optimalizovány užitím čar elektrického pole. Chrupavka je poté segmentována užitím mnohovrstevnatého grafu, který je rozvrstven znalostí o poloze chrupavky vzhledem k přilehlým kostem.

Algoritmus je citlivý na abnormality (v jednom případě například segmentace selhala, neboť chrupavka měla přílišnou tloušťku). Proto je třeba na něm ještě zapracovat a rozšířit trénovací databázi dat. Algoritmus zabere zhruba 20 minut na jeden obraz, z toho hrubá segmentace kostí zabírá zhruba 6 minut. Důležitým parametrem pro funkčnost softwaru je nastavení rozmazání obrazu.



Obr. 5.5 – Segmentace artikulární chrupavky metodou LOGISMOS [20]

Lee ve článku [21] vyvinul plně automatickou metodu, která se skládá ze segmentace kostí a následnou extrakcí rozhraní chrupavka-kost a segmentací chrupavky. Rozhraní chrupavka-kost je nalezeno pomocí k-NN klasifikátoru, založeného na pozici voxelu. Chrupavka je segmentována použitím graph-cut metody, a to funkcí minimalizace energie, skládající se z unární a párové

pravděpodobnosti. Unární pravděpodobnost závisí na lokálním histogramu chrupavky a párová je pravděpodobností nalezení hranice ve specifické lokaci v obraze. Výsledkem je několik lokálních segmentací, které se zkombinují do masky.

Software byl testován porovnáním s manuální segmentací prováděnou dvěma experty. Chrupavku se ovšem podařilo segmentovat zhruba jen na každém třetím snímku. Při použití většího tréninkového setu dat byl algoritmus schopen rozpoznat větší množství variací chrupavek. Z toho vyplývá, že čím více tréninkových dat, tím pravděpodobnější je úspěšnost algoritmu.

5.3 Poloautomatická segmentace

Účelem poloautomatické segmentace je snaha o minimalizaci zásahů uživatele během právě probíhající segmentace. Úkolem uživatele je pouze nasměrování algoritmu správným směrem. Tato metoda obvykle vyžaduje inicializaci uživatelem softwaru.

Poloautomatické metody můžeme rozdělit podle způsobu, na jakém fungují, na založené na:

1. Intenzitě – prahování, rozvodí
2. Detekci hran
3. Minimalizaci energie – „Live wire“, aktivní kontury


5.3.1 Segmentace založená na intenzitě

V práci [22] byl autory vymezen manuálně region zájmu zvlášť pro každý řez. Software poté udává střední hodnotu specifického regionu a uživatel pak už jen musí specifikovat prahovací hodnotu. Všechny voxely s hodnotou vyšší než prahovací jsou poté klasifikovány jako chrupavka. Algoritmus byl aplikován na čtyři pacienty s osteoartrózou a dva s další patologií chrupavky.

Prahovací krok závisí na střední intenzitě, která je vypočítána z oblasti zájmu zvolené uživatelem. Proto by tato oblast neměla zahrnovat mnoho kostní tkáně. Dále záleží na tloušťce řezu, která pokud je příliš vysoká, může způsobit chybu. Přesnost softwaru byla při testování stanovena na 82–99 %.

Ve článku [23] je rozebrána modifikovaná verze segmentace rozvodím (angl. *watershed*). Nejprve je obraz rozmazán pomocí anizotropního filtru. Následně je nutné označit 3 typy tkání: kost, chrupavčitou tkáň a ostatní měkké tkáně, které jsou považovány za lokální minima. Algoritmus se poté snaží nalézt ostatní sekce, které jsou nad úroveň těchto lokálních minim. Problém tzv. přesegmentování je vyřešen aplikací geodetické rekonstrukce, a optimalizován užitím seřazených řad. Namísto použití gradientního obrazu jako vstupního pro segmentaci rozvodím, autoři uvádí funkci, která vypočítá pravděpodobnost nalezení hrany mezi označenými a neoznačenými voxely. Intenzity mezi rozdílnými tkáněmi vykazují normální rozdělení a vnitřně projevují prostorovou homogenitu.

Přesnost poloautomatické segmentace byla určena jako adekvátní manuální segmentaci. V inicializačním kroku musí být nadefinováno 50 bodů pro každý typ tkáně, což zabere asi 5-10 minut. Volba umístění bodů je velmi důležitá. Software byl testován na 7 snímcích kolenní chrupavky a na několika MR zobrazeních mozku z atlasu.



Obr. 5.6 – Segmentace rozvodím [23]

5.3.2 Detekce hran


Ve článku [24] Akhtar popisuje metodu zobrazení tloušťky femorální chrupavky na 3D mřížce. Algoritmus byl implementován v prostředí MATLAB. Nejprve uživatel musí opět nadefinovat oblast zájmu pro každý řez. Pro jednotlivé řezy lze oblast nakopírovat, pokud se příliš nemění pozice chrupavky. Ze středového bodu vychází několik paprsků s krokem 4° . Pomocí detekce hran je každý paprsek prozkoumán, dokud software nenarazí na okraj chrupavky. Okrajové body jsou poté nakombinovány do 3D mřížky užitím B-spline interpolace. Nakonec je změřena tloušťka chrupavky pomocí měření tloušťky 3D mřížky. Přesnost algoritmu byla stanovena porovnáním s manuální segmentací.

Bohužel byl tento algoritmus testován pouze na zdravých jedincích, a proto není jisté, že správně detekuje tloušťku chrupavky u pacientů s patologií, například s osteoartrózou. Nevýhodou je nutnost selekce oblasti zájmu pro každý řez zvlášť. Dále tato metoda vyžaduje přiměřenou kvalitu obrazu (vysoký kontrast na přechodu tkání, ostré hrany apod.), což je ne vždy reálné.

Ve článku [25] autor vyvinul uživatelské rozhraní, jež je implementováno v jazyce C, které využívá filtry pro detekci hran pro každý typ chrupavky. Nejprve uživatel zadá bod na rozhraní chrupavka-kost a algoritmus se poté pokusí segmentovat chrupavku pomocí detekce hran zvlášť pro rozhraní chrupavka-kost a zvlášť pro rozhraní chrupavka-měkká tkáň. Uživatel může do segmentace zasáhnout, aby opravil chyby, a následně je struktura přetvarována použitím aktivních kontur. Segmentovaný tvar je poté přemístěn do následujícího řezu a optimalizován opět použitím aktivních kontur. Proces je opakován pro každou subsekcí kolenní chrupavky, přičemž tibiální chrupavka je považována za dvě sekce.

Autor poskytuje širokou škálu nastavení pro manipulaci se segmentačním procesem. Avšak práce s tímto rozhraním vyžaduje trénink. Časová náročnost je srovnatelná s manuální segmentací, a proto není zřetelná žádná výraznější výhoda této metody.

Obr. 5.7 a) znázorňuje obraz během detekce hran b) znázorňuje hrubě segmentovanou chrupavku a c) zobrazuje finální segmentaci po použití aktivních kontur



Obr. 5.7 – Segmentace artikulární chrupavky poloautomatickým softwarem J. Duryea [25]

5.3.3 Minimalizace energie

Gougoutas ve článku [26] používá techniku Live Wire, kdy uživatel pohybuje myší podél hrany chrupavky, zatímco algoritmus vypočítává nejlepší cestu podél ní v reálném čase. Nejprve je nutné, aby uživatel definoval bod, ležící na hraně chrupavky a dále pohyboval myší ve směru jeho kontury. Algoritmus vypočítá hodnotu pixelu kloubu. Software si sám vypočítává parametry jako je intenzita na obou stranách hrany, hodnota gradientu v různých orientacích, vzdálenost od předchozí hranice. Pro každou sekci je nutné znovu nadefinovat počáteční bod.


Algoritmus byl zatím testován zejména na fantomech, na kterých je obtížné nasimulovat skutečný klinický obraz. Dále byl testován na patelární chrupavce, která má oproti femorální a tibiální chrupavce pravidelný tvar, a je tedy jednodušší její segmentace. Proto zatím není jasné, zdali by tento algoritmus obstál při segmentaci degenerované chrupavky. Nicméně je tato metoda podstatně méně časově náročná oproti manuální segmentaci.

Kauffmann ve článku [27] používá lokální koordinační systém a striktní objektové záznamy pro vyhodnocení dlouhodobých studií artikulární chrupavky. Uživatel softwaru inicializuje linii poblíž chrupavky a vnější oblast chrupavky je poté extrahována pomocí aktivních kontur. Extrahovaná část je následně využita pro inicializaci následujícího řezu.

Pro porovnání chrupavky v několika časových liniích je třeba jednotlivé segmentace propojit navzájem, protože pozice a orientace kolena se má tendenci při každém skenování měnit. Autoři tvrdí, že při dlouhodobých studiích prochází změnami především pohybová část chrupavky, a proto je logické lokální koordinační systém připodobnit k rozhraní chrupavka-kost. Femorální chrupavka je následně transformována do cylindrických souřadnic koordinačního systému a tibiální chrupavka je mapována do planárního koordinačního systému. Každý bod geometrického systému je definován jako offset pro nejbližší bod kontury chrupavky. Mapa tloušťky chrupavky je generována výpočtem vzdálenosti mezi offsetem rozhraní chrupavka-kost a mezi offsetem bodu hrany chrupavky.

Algoritmus byl testován na syntetickém MR obrazu kolena. Jednotlivé intenzity tkání byly odvozeny z jednotlivých intenzit skrze 100 pořízených obrazů. Obrazy byly zbaveny šumu, použitím Ricianovy pravděpodobnostní distribuční funkce. Protože syntetický obraz poskytuje vysoký kontrast mezi chrupavkou a pozadím, není jasné, jak by tento algoritmus reagoval na obraz skutečný. Při testování

byla nakonec poziční chyba menší než minimální velikost voxelu a koeficient změny objemu byl asi 0,1 %.



Obr. 5.8 – Syntetický obraz MR; a) tibiální chrupavka; b) femorální chrupavka [27]

5.4 Závěr

Existuje mnoho způsobů detekce objektu v obrazu. V této rešerši jsem se zabývala několika metodami, přičemž každá má své pro a proti a výsledek téměř vždy záleží na typu a kvalitě vstupního obrazu.

Metoda sledování hran je vhodnou volbou, pokud existuje jasný kontrast mezi chrupavkou a okolními tkáněmi. Můžeme ji bezpečně kombinovat s filtry pro odstranění šumu, protože nezávisí přímo na hodnotách intenzit, ale na přechodu mezi nimi. Typicky je detekce hran použita na 2D snímcích a nakombinována do mřížky užitím interpolace souřadnic. Je využívána především u MR obrazů, které byly pořízeny za působení silného magnetického pole. Metoda bývá neúspěšná při přímém kontaktu dvou chrupavek, kvůli jejich vysoké homogenitě.

Algoritmy založené na intenzitě často pracují na principu rozdělení obrazu pomocí prahování. Segmentace rozvodím je užitečná při vysokých gradientech v obrazu. Dochází k postupné expanzi nadefinovaných křivek a hranice mezi takto vzniklými plochami je hledanou linií. Tato metoda má ale své nevýhody, jako je přesegmentování, je velmi citlivá na šum a neschopná detekovat velmi tenké struktury obrazu. To může být problém v klinické praxi, kdy patologická chrupavka může nabývat tloušťky menší než je šířka jednoho voxelu. Další nevýhodou je nutnost inicializace bodů manuálně.

V analýze textur jsou voxely rozděleny prahováním. Metoda vyžaduje minimální překrytí tkání v obraze a její účinek závisí na použité sekvenci MRI a na kvalitě obrazu.

Graph-cut metoda je účinná při segmentaci chrupavky z několika důvodů. Metoda je odolná proti šumu, umí se vypořádat s neobvyklými tvary, je možnost zvolit hodnotu energie několika způsoby. Jedinou nevýhodou je nutnost inicializace metody – buďto manuálně umístěním bodů nebo automaticky před-segmentací.

Metoda k-NN je výhodná pouze při skenování nízkým magnetickým polem při MRI a navíc vyžaduje post-zpracování obrazu.

Z této rešerše vyplývá, že volba segmentační metody záleží na kvalitě snímků, které máme k dispozici, na povaze detekované patologie a celkové povaze snímku. Zlatým standardem zůstává však v dnešní době i nadále manuální segmentace.

6 Aktivní kontury

Metoda aktivních kontur je jedna z pokročilejších metod segmentace obrazu. Spadá do tzv. deformovatelných modelů a lze si ji představit jako definovatelnou křivku v daném obraze, která na základě působení energií deformuje postupně svůj tvar, až do té chvíle, dokud nedosáhne hranice námi segmentovaného útvaru. Hlavní výhodou aktivní kontury je její uzavřenost. V případě detekce objektu s nejasnou nebo chybějící hranou po celé délce je křivka kontury tuto hranu schopna nahradit. Při jejím počátečním umístění v obraze je důležité, aby byla křivka definována v blízkosti objektu, který chceme segmentovat. V opačném případě může být přitahována artefakty v obraze a okolními objekty a segmentace tedy není úspěšná. [28]

6.1 Parametrické aktivní kontury

Poprvé byla tato metoda popsána v roce 1987 v práci Kasse, Witkina a Terzopoulou [28], kde jsou aktivní kontury také nazývány jako hadi (angl. *snakes*). Křivka je podle těchto autorů ovlivňována několika energiemi. Vnitřní energie ovlivňuje hladkost a táhlost křivky a zabráňuje vzniku rohů, energie obrazu zajišťuje přitahování křivky k liniím a hranám a vnější energie přitahuje křivku k lokálním minimům. Počáteční umístění křivky je nadefinováno buď přímo uživatelem softwaru, nebo předem nastaveným algoritmem. [28]

Celková energie aktivní kontury je součtem vnitřní energie, vnější energie a energie obrazu. Uvažujeme křivku definovanou parametrickou rovnicí $v(s) = (x(s), y(s))$, kde $s = 0$ značí počátek křivky, $s = 1$ značí konec křivky a $x(s), y(s)$ značí souřadnice bodu ležícího na křivce. Celková energie se potom vypočítá ze vztahu: [28]

$$\begin{aligned} E_{snake}^* &= \int_0^1 E_{snake}(v(s)) ds \\ &= \int_0^1 E_{int}(v(s)) ds + \int_0^1 E_{image}(v(s)) ds + \int_0^1 E_{con}(v(s)) ds \end{aligned} \quad (1)$$

kde E_{int} reprezentuje vnitřní energii, externí energie je ve vztahu rozdělena na E_{image} a E_{con} . E_{image} je energie obrazu a E_{con} je energie bodů počáteční kontury.

6.1.1 Interní energie

Interní energie je definována vzorcem: [28]

$$E_{int} = \alpha(s) \left| \frac{\partial s}{\partial s} \right|^2 + \beta(s) \left| \frac{\partial s}{\partial s} \right|^2 \quad (2)$$

kde α je parametr, který udává pevnost křivky působící proti roztažení a snaží se minimalizovat vzdálenost mezi jednotlivými body. Parametr β udává tuhost proti stlačení a reprezentuje pružnost křivky. Nastavením těchto dvou parametrů můžeme definovat, jakým způsobem se bude kontura formovat v rozích a zda bude mít hladký průběh, nebo bude přesně kopírovat hrany objektu.

6.1.2 Energie obrazu

Energie obrazu je součástí externí energie a je definována: [28][29]

$$E_{Image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term} \quad (3)$$

E_{line} , E_{edge} a E_{term} jsou tři energetické funkce, které matematicky popisují zkoumaný obraz.

Funkce E_{line} :

Tato funkce využívá jasové intenzity v bodě (x, y) . Pokud použijeme při předzpracování Gaussův filtr, intenzitu jím pouze vynásobíme (5). Kontura bude inklinovat buď ke světlým, nebo ke tmavým oblastem obrazu v závislosti na volbě konvence w_{line} .

$$E_{line} = I(x, y) \quad (4)$$

$$E_{line} = G_{\sigma}(x, y) \cdot I(x, y) \quad (5)$$

Funkce E_{edge} :

V tomto případě je kontura inklinována do oblasti s vysokou hodnotou gradientu (tedy do lokálního minima). Výhodné je opět použití některého z filtrů, a to protože oblast našeho zájmu může být zašuměná, popř. gradient může být v dané lokaci málo výrazný.

$$E_{edge} = -|\nabla I(x, y)|^2 \quad (6)$$

Funkce E_{term} :

Tato funkce detekuje konce hran a ostré hrany. Opět zde využíváme mírného rozmazání obrazu pomocí Gaussova filtru. Funkci vypočítáme dle vztahu:

$$E_{term} = \frac{\partial \theta}{\partial n_x} = \frac{\partial^2 C / \partial n_x^2}{\partial C / \partial n} = \frac{C_{yy}C_x^2 - 2C_{xy}C_xC_y + C_{xx}C_y^2}{(C_x^2 + C_y^2)^{3/2}} \quad (7)$$

kde C reprezentuje rozmazaný obraz (8), θ je úhel gradientu (9) a n a n_x jsou vektory rovnoběžný a kolmý ke směru gradientu (10)(11):

$$C(x, y) = G_{\sigma}(x, y) \cdot I(x, y) \quad (8)$$

$$\theta = \tan^{-1} \frac{C_y}{C_x} \quad (9)$$

$$n = (\cos \theta, \sin \theta) \quad (10)$$

$$n_x = (-\sin \theta, \cos \theta) \quad (11)$$

6.2 Geometrické aktivní kontury

Geometrické aktivní kontury mají několik výhod oproti klasickému parametrickému modelu aktivních kontur. Jedna z hlavních je možnost segmentovat několik objektů z obrazu najednou. Jedna z nejznámějších metod geometrických aktivních kontur je metoda bez hran Chan-Vese, která je popsána v následující deskripci. Nejprve je ale nutné si nadefinovat level-set metodu, ze které metoda aktivních kontur bez hran vychází. [30][31]

6.2.1 Level-set metoda

V následujícím popisu této metody se budeme pohybovat v dvojrozměrném prostoru, přestože metoda jde nadefinovat i pro více dimenzí. Funkce má tvar $\phi_{x,t}$, kde $x = (x, y)$ jsou souřadnice bodů a t je čas. V čase t křivka $\phi_{x,t}$ rozděluje rovinu na dvě části. [30][31]

Pro zjednodušení si můžeme level-set funkci nadefinovat jako jednotkovou kružnici se středem v bodě $(0,0)$:

$$\phi_{x,y} = x^2 + y^2 - 1 \quad (12)$$

Pomocí kružnice definujeme vnější oblast Ω^+ :

$$\phi_{x,y} > 0 \quad (13)$$

Vnitřní oblast Ω^- definujeme:

$$\phi_{x,y} < 0 \quad (14)$$

Obecně tedy lze aktivní konturu zapsat:

$$\Gamma_t = \{x | \phi_{x,t} = 0\} \quad (15)$$

Pro každý bod ležící ve vnitřní nebo vnější oblasti lze spočítat vzdálenost od bodu ležícího na kružnici pomocí funkce d_x : [30]

$$d_x = \min(|x - x_c|) \quad (16)$$

kde $x = (x, y)$ je libovolný bod v rovině a $x_c = (x, y)_c$ je bod na křivce.

Každá hodnota x je potom dána konvencí a vzdáleností. Platí, že body ležící uvnitř křivky mají zápornou hodnotu a body ležící vně mají hodnotu kladnou. [30]

6.2.2 Aktivní kontury bez hran

Tento model vychází z Mumford-Shahova funkcionálu. Pomocí něj lze segmentovat popředí od pozadí pomocí minimalizace následujícího funkcionálu: [30][31]

$$E(c_1, c_2, \Gamma) = \alpha \int_{\Omega^+} (n_{x,y} - c_1)^2 dx dy + \beta \int_{\Omega^-} (n_{x,y} - c_2)^2 dx dy + \gamma \int_p |\Gamma_p| dp \quad (17)$$

kde c_1, c_2 je průměrná hodnota intenzity ve vnitřním a vnějším prostoru, $n_{x,y}$ je hodnota intenzity bodů ve vnitřním a vnějším prostoru a Γ je hranice, kde p jsou body ležící na ní. Poslední člen tedy zajišťuje hladkost průběhu křivky.

Pomocí Heavisidovy funkce je možnost oddělit popředí obrazu od pozadí podle vztahu:

$$H(\phi_{x,y}) = \begin{cases} 1, & \phi_{x,y} \geq 0 \\ 0, & \phi_{x,y} < 0 \end{cases} \quad (18)$$

a Mumford-Shahův funkcionál poté lze přepsat jako: [30]

$$\begin{aligned} F(c_1, c_2, \phi) = & \mu \int_{\Omega} |\nabla H(\phi_{x,y})| dx dy + v \int_{\Omega} H(1 - \phi_{x,y}) dx dy \\ & + \lambda_1 \int_{\Omega} |n_{x,y} - c_1|^2 (1 - H(\phi_{x,y})) dx dy \\ & + \lambda_2 \int_{\Omega} |n_{x,y} - c_2|^2 H(\phi_{x,y}) dx dy \end{aligned} \quad (19)$$

Hodnoty c_1, c_2 jsou průměrné hodnoty popředí a pozadí a můžeme je vyjádřit: [30]

$$c_1 = \frac{\int_{\Omega} n_{x,y} \cdot (1 - H(\phi_{x,y})) dx dy}{\int_{\Omega} (1 - H(\phi_{x,y})) dx dy} \quad (20)$$

$$c_2 = \frac{\int_{\Omega} n_{x,y} \cdot H(\phi_{x,y}) dx dy}{\int_{\Omega} H(\phi_{x,y}) dx dy} \quad (21)$$

Koeficienty μ, v, λ_1 a λ_2 jsou váhové koeficienty jednotlivých členů. První člen určuje délku hranice, druhý zajišťuje minimalizaci popředí (oblasti uvnitř kontury) a poslední dva členy obdobně jako v (17) popisují odchylku intenzity bodů v popředí a pozadí od průměrných hodnot v daných prostředích. [30]

7 Automatizovaná segmentace artikulární chrupavky

Cílem práce je segmentovat a extrahovat artikulární chrupavku kolene s vyhlídkou budoucího využití metody pro volumetrická měření a vytvoření 3D modelu chrupavky. Dílčími cíli je detekovat konturou počínající osteoartrické změny, validovat výsledky pomocí manuální segmentace a následně určit procentuální úspěšnost metody u každého snímku a otestovat efektivitu metody pro jiné sekvence magnetické rezonance.

Postup řešení zahrnuje předzpracování snímků z datasetu, implementaci metody aktivních kontur a její testování na snímcích pro různá nastavení parametrů, komparativní analýzu algoritmu s funkcí *activecontour()* v MATLABu, testování výpočetní náročnosti pro různý počet iteračních kroků a validaci výsledků a vyhodnocení jednotlivých částí za účelem dosažení co nejlepšího výsledku segmentace artikulární chrupavky. Celkový postup řešení je nastíněn v diagramu na Obr. 7.1.



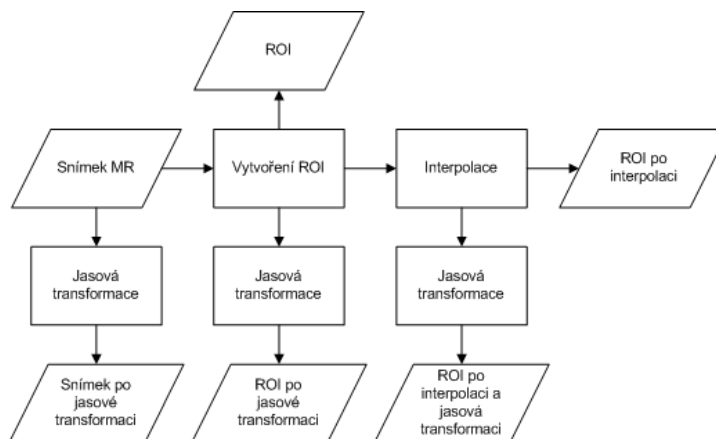
Obr. 7.1 – Vývojový diagram obecného postupu segmentace aktivními konturami

Analyzovaný dataset obsahuje snímky artikulární chrupavky kolene z magnetické rezonance o síle 1,5 T. Zobrazení je proton-denzní s využitím techniky pro potlačení tukové tkáně. Snímky zobrazují artikulární chrupavky s počínajícími osteoartrickými změnami.

7.1 Předzpracování snímků

Předzpracování se provádí za účelem zlepšení vlastností snímků a očekávaných výsledků. V této práci provádím pouze základní úpravy se zacílením na zvýraznění přechodu chrupavka-měkká tkáň, zjemnění hran chrupavky navýšením počtu pixelů a usnadnění inicializace počáteční křivky zvětšením oblasti s chrupavkou.

Při předzpracování využívám tři metody: vytvoření ROI, jasovou transformaci a interpolaci obrazu. Při testování metody aktivních kontur budu také porovnávat, které z kombinací těchto metod měly kladný dopad na segmentaci. Obr. 7.2 zobrazuje postup a výstupy předzpracování snímků v mé práci.




Obr. 7.2 – Vývojový diagram předzpracování snímků

7.1.1 Vytvoření ROI

Vytvoření tzv. oblasti zájmu (angl. *region of interest*) je podstatná část předzpracování z hlediska výpočetní náročnosti metody aktivních kontur a také z důvodu zjednodušení inicializace počáteční kontury, která se kvůli malým rozměrům artikulární chrupavky obtížně do nativního snímku umísťuje. Vytvořením ROI jsme schopni snížit počet pixelů obrazu až na polovinu, nicméně po následném přiblížení lze přímo vidět jednotlivé pixely, a proto výsledná křivka kopírující jejich tvar není úplně přesná a kontinuální. Tímto problémem se hodlám zabývat v podkapitole o interpolaci.


V prostředí MATLAB lze vybrat oblast zájmu buďto manuálně, nebo zadáním konkrétních souřadnic. Pro účely této práce jsem zvolila oblast u každého snímku manuálně, a to kvůli variabilitě jednotlivých snímků. Oblastí zájmu v tomto případě bude artikulární chrupavka a její blízké okolí.



Obr. 7.3 – Porovnání nativního snímku (vlevo) a extrahovaného ROI (vpravo)


7.1.2 Jasová transformace

Dalším krokem předzpracování je jasová transformace, konkrétně změna kontrastu snímku. Cílem této transformace je zvýraznit tkáň chrupavky (oblasti s vyšší jasovou intenzitou) a potlačit okolní měkké tkáně (oblasti s nižší jasovou intenzitou). Předpokladem je, že po této transformaci bude použití metody snadnější, rychlejší a kontura nebude mít tendenci se rozpínat do oblastí měkkých tkání. Nežádoucím jevem je ale zvýraznění obrazových artefaktů, což může být pro segmentaci komplikací.



Obr. 7.4 – Graf jasové transformace použité pro snímky z datasetu

Jasová transformace se v prostředí MATLAB provádí změnou konkrétních hodnot pixelů zadáním původních hodnot a nových, změněných hodnot. Tím lze potlačit nebo zvýraznit tmavší nebo světlejší oblasti snímku. Na Obr. 7.4 je znázorněna křivka jasové transformace snímků z datasetu. Transformace je lineární a z grafu je patrné, že všechny pixely s hodnotou nižší než 0,2 jsou potlačeny, zatímco všechny pixely s hodnotou vyšší než 0,85 jsou zvýrazněny. Na Obr. 7.5 vlevo je umístěn nativní snímek. Vpravo je pro srovnání umístěn snímek po jasové transformaci, na němž je pouhým okem viditelné zvýraznění chrupavčité tkáně a potlačení měkkých tkání, ale jen natolik, aby nedošlo k přílišné ztrátě obrazové informace.



Obr. 7.5 – Snímek kolene před (vlevo) a po (vpravo) jasové transformaci

7.1.3 Interpolace

Interpolace obrazu je proces, který vypočítává nové body obrazu na základě těch původních. Pomocí interpolace tedy zvětšujeme jeho rozlišení. Nové body jsou vypočítávány proložením těch původních křivkou. Stupeň interpolace udává, kolik nových bodů je z původních vypočítáno. Podle toho, jakou má křivka povahu a kolik využívá původních bodů, existuje několik základních typů interpolace: [32]

1) Metoda nejbližšího souseda

Tato metoda se považuje za nejjednodušší interpolační metodu. Princip spočívá v tom, že při výpočtu nového bodu se duplikuje hodnota nejbližšího originálního bodu. Výhodou metody je její rychlost, jednoduchost a zachování hran, nicméně velikou nevýhodou je ztráta hladkosti na hranových přechodech.

2) Lineární interpolace

Lineární nebo ve zpracování obrazu bilineární interpolace funguje na principu proložení originálních pixelů lineární křivkou. Na této křivce jsou následně váženým průměrem vypočítávány nové body. Ve 2D grafice jsou nové body vypočítávány ze 4 původních bodů.


3) Kvadratická interpolace

Kvadratická interpolace spočívá v proložení diskrétní funkce parabolou. Tato interpolace je daleko přesnější než lineární a také vyžaduje pro svůj výpočet větší počet originálních bodů.

4) Kubická interpolace

Kubická interpolace je svým principem podobná té kvadratické. Rozdíl tkví v tom, že místo polynomicke křivky druhého řádu se využívá polynomicke křivky třetího řádu a tento typ interpolace využívá 16 vstupních bodů, čímž se zvyšuje kontinuita obrazu v oblasti hran.

Na Obr. 7.6 jsou pro srovnání vedle sebe položeny přiblížené oblasti stejného snímku artikulární chrupavky. Vlevo je umístěna oblast přiblížení bez interpolace, vpravo je přiblížená stejná oblast po kubické interpolaci druhého stupně. Na obrázku vpravo je na první pohled vidět, že počet pixelů se zdvojnásobil.



Obr. 7.6 – Oblast přiblížení snímku bez interpolace (vlevo) a s interpolací (vpravo)

Z důvodu požadované kvality obrazů pro účely úspěšné segmentace jsem zvolila interpolaci kubickou. Následně bylo nutno zvážit kompromis mezi výpočetní náročností interpolační funkce a zvoleném stupni interpolace.




Obr. 7.7 – Graf závislosti výpočetní náročnosti na zvoleném stupni interpolace

Na Obr. 7.7 je zobrazena závislost výpočetní náročnosti kubické interpolace právě na zvoleném stupni interpolace. Tato závislost byla naměřena u ROI snímku z datasetu o velikosti 448x302 pixelů. Nakonec jsem pro účely segmentace zvolila interpolaci třetího stupně, která trvala u tohoto snímku 16,2 s.

7.2 Implementace metody aktivních kontur

Dalším postupem je implementace metody aktivních kontur v MATLABu a práce s parametry funkce. Předlohou pro implementaci mi byl kód Li Wanga, který čerpá ze článku [33]. Jedná se o metodu aktivních kontur bez hran, která je přizpůsobena snímkům s vysokým obsahem šumu a s jasovou nehomogenitou. Princip kódu je zobrazen na Obr. 7.8.



Obr. 7.8 – Vývojový diagram implementované metody

7.2.1 Matematický podklad metody

Autor zavádí nový energetický funkcionál, který představuje rozložení intenzit jednotlivých bodů:

$$E^{LGDF} = \int_{\Omega} E_X^{LGDF} dx = \int_{\Omega} \left(\sum_{i=1}^N \int_{\Omega_i} -\omega(x-y) \log p_{i,x}(I(y)) dy \right) dx \quad (22)$$

kde $p_{i,x}(I(y))$ je funkce rozložení hustoty pravděpodobnosti v regionu Ω_i , $\omega(x-y)$ je váhová funkce a $-\log$ představuje přechod od maximalizace k požadované minimalizaci. Dvojitý integrál je definován z důvodu, aby došlo k minimalizaci funkcionálu E_X^{LGDF} pro všechny body x v obrazové doméně Ω .

Předpokladem je, že obrazovou doménu lze rozdělit na dvě oblasti: popředí a pozadí level-setové funkce ϕ . Použitím Heavisidovy funkce lze energii vyjádřit jako:

$$\begin{aligned} E_X^{LGDF}(\phi, u_1(x), u_2(x), \sigma_1(x)^2, \sigma_2(x)^2) \\ = - \int \omega(x-y) \log p_{1,x}(I(y)) M_1(\phi(y)) dy \\ - \int \omega(x-y) \log p_{2,x}(I(y)) M_2(\phi(y)) dy \end{aligned} \quad (23)$$

kde $M_1(\phi(y)) = H(\phi(y))$ a $M_2(\phi(y)) = 1 - H(\phi(y))$ a lze tedy energii přepsat jako:

$$E^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = \int_{\Omega} E_X^{LGDF}(\phi, u_1(x), u_2(x), \sigma_1(x)^2, \sigma_2(x)^2) dx \quad (24)$$

Pro přesnější evoluci kontury je nutná regularizace level-setové funkce, která zabrání odchýlení kontury od dané vzdálenosti:

$$P(\phi) = \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad (25)$$

Dále je nutná regularizace nulové level-setové funkce omezením její délky:

$$L(\phi) = \int |\nabla H(\phi(x))| dx \quad (26)$$

a celkový energetický funkcionál lze poté přepsat jako:

$$F(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL(\phi) + \mu P(\phi) \quad (27)$$

kde $v, \mu > 0$ jsou váhové konstanty. V praxi lze Heavisidovu funkci aproximovat funkcí rozmazání definovanou:

$$H_\varepsilon = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan \left(\frac{x}{\varepsilon} \right) \right] \quad (28)$$

Její derivace je potom:

$$\delta_\varepsilon = H'_\varepsilon(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2} \quad (29)$$

Energetický funkcionál je poté aproximován jako:

$$F_\varepsilon(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E_\varepsilon^{LGDF}(\phi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL_\varepsilon(\phi) + \mu P(\phi) \quad (30)$$

přičemž jeho minimalizaci řeší rovnice gradientního klesajícího toku:

$$\frac{\partial \phi}{\partial t} = -\delta_\varepsilon(\phi)(e_1 - e_2) + v\delta_\varepsilon(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left(\nabla^2(\phi) - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right) \quad (31)$$

kde:

$$e_1(x) = \int_{\Omega} \omega(y - x) \left[\log(\sigma_1(y)) + \frac{(u_1(y) - I(x))^2}{2\sigma_1(y)^2} \right] dy \quad (32)$$

$$e_2(x) = \int_{\Omega} \omega(y - x) \left[\log(\sigma_2(y)) + \frac{(u_2(y) - I(x))^2}{2\sigma_2(y)^2} \right] dy \quad (33)$$

Pro účely segmentace artikulární chrupavky bylo nutné především precizně nastavit parametry funkce: [33][34][35]


- **n (NumIter)** – počet iteračních kroků.
- **Δt (timestep)** – časový krok posunu křivky (čím vyšší je hodnota parametru, tím rychleji se křivka pohybuje, ale s většími nepřesnostmi).
- **μ (mu)** – konstanta, která zajišťuje, aby se křivka neodchýlila příliš daleko od své aktuální pozice během své evoluce.
- **α (alf)** – konstanta, díky které lze při evoluci křivky nastavit důraz kladený na energii obrazu, která přitahuje křivku ke hranám.
- **v (nu)** – konstanta, která ovlivňuje délku kontury. Čím je hodnota tohoto parametru nižší, tím větší délky může kontura při své evoluci nabývat, ale naopak může být přitahována nežádoucími artefakty obrazu.
- **c_0 (c0)** – touto konstantou se násobí hodnoty pixelů uvnitř kontury (její zápornou hodnotou) a vně kontury (její kladnou hodnotou). Vyšší hodnota zajišťuje rychlejší počáteční pohyb právě inicializované kontury.
- **ε (epsilon)** – udává šířku Diracova impulsu, který zrychluje počáteční pohyb právě inicializované kontury. Čím vyšších hodnot nabývá, tím méně přesná je finální kontura.

- σ (**sigma**) – jedná se o parametr Kernelovy funkce, která částečně řeší nehomogenitu jasové intenzity. Čím je hodnota parametru vyšší, tím více se křivka při své evoluci vzdaluje od své aktuální pozice během jednoho iteračního kroku.
- λ_1 (**lambda1**) – konstanta, která násobí funkci $e_1(x)$ a tedy přikládá váhu oblasti uvnitř kontury při pohybu křivky.
- λ_2 (**lambda2**) – konstanta, která násobí funkci $e_2(x)$ a tedy přikládá váhu oblasti vně kontury při pohybu křivky.

V závorce je vždy uvedeno, jak je parametr pojmenován v příloženém kódu. U parametrů λ_1 a λ_2 záleží také kromě hodnoty na jejich vzájemném poměru. Pokud je hodnota parametru λ_1 větší než hodnota λ_2 , má křivka tendenci se smršťovat. Pokud je nerovnost opačná, má křivka tendenci expandovat.

7.2.2 Umístění inicializační kontury

Jako inicializační konturu lze využít jakoukoli křivku uzavřeného tvaru. V kódu lze implementovat křivku její parametrickou rovnicí. Evoluce kontury, znázorněná na Obr. 7.9, je prováděna po iteračních krocích, přičemž výsledky jsou průběžně zobrazovány. Kvůli výpočetní náročnosti je výhodné aktuální posun kontury zobrazovat vždy až po několika krocích. Po provedení všech iteračních kroků je výsledkem obraz se zvýrazněnou finální konturou, která obepíná námi segmentovaný obraz.



Obr. 7.9 – Evoluce křivky od inicializační kontury po finální konturu, počet iterací = 350

Počet iteračních kroků výrazně ovlivňuje výpočetní náročnost softwaru. Při testování algoritmu se zabýváme také ideálním počtem iterací v závislosti na výpočetní době.

7.3 Testování algoritmu

Testování metody bude probíhat na všech uvedených typech předzpracování obrazu i na nativních snímcích a výsledky budou poté porovnávány s již naimplementovanou funkcí v prostředí MATLAB. Na závěr provedu analýzu výpočetní náročnosti a validaci pomocí manuální segmentace. Výstupem bude binární obraz, u nějž je možné vypočítat obsah extrahované oblasti.

7.3.1 Funkce `activecontour()`


Funkce `activecontour()` je přednastavená funkce v prostředí MATLAB. Tuto funkci jsem si zvolila jako referenční mez pro danou problematiku segmentace. Vstupem funkce je obraz s námi požadovaným objektem segmentace a binární maska, tedy inicializační kontura. Tu lze navolit parametricky nebo manuálně. Další parametry funkce umožňují zvolit metodu aktivních kontur (s hranovou detekcí nebo bez hran), počet iterací, faktor rozmazání a faktor evoluce křivky. Výstupem je binární obraz, kde bílá barva zobrazuje segmentovanou oblast. Po vynásobení tohoto binárního obrazu s původním dostaneme segmentovanou oblast s originálními hodnotami pixelů.

Faktor rozmazání (*SmoothFactor*) udává stupeň rozmazání hran segmentované oblasti. Vyšší hodnota této konstanty udává vyšší stupeň rozmazání, ale může také rozmazat finální detaily, což je pro segmentaci nežádoucí. Nižší hodnota zajišťuje zachycení více detailů, ale křivka není natolik táhlá a kontinuální. Přednastavená hodnota tohoto faktoru je pro metodu bez hran 0 a pro hranovou detekci 1.

Faktor evoluce křivky (*ContractionBias*) ovlivňuje pohyb kontury, tedy zda bude expandovat či se stahovat dovnitř. Pozitivní hodnoty parametru mají vliv na smršťování kontury, negativní na roztahování. Hodnota ovlivňuje také rychlost pohybu kontury.

Testování funkce:


Pro metodu aktivních kontur s hranovou detekcí jsem vyhodnotila jako nejefektivnější následující nastavení parametrů: $\text{SmoothFactor} = 0,8$, $\text{ContractionBias} = 0,24$.



Obr. 7.10 – Segmentace chrupavky funkcí `activecontour()` s hranovou detekcí


Obr. 7.10 zobrazuje vlevo inicializační masku a vpravo výslednou segmentaci chrupavky. I přes různá nastavení parametrů se mi nepodařilo segmentaci provést s větší přesností.

Obr. 7.11 zobrazuje pokus o detekci počátečních osteoartritických změn přednastavenou funkcí. Lze vidět, že i přes nedokonalou segmentaci chrupavky byla osteoartróza detekována.



Obr. 7.11 – Zkouška detekce osteoartrózy funkcí activecontour() s hranovou detekcí

Pro metodu aktivních kontur bez hran jsem zvolila nastavení parametrů: SmoothFactor = 0,15, ContractionBias = 0,268.



Obr. 7.12 – Segmentace chrupavky funkcí activecontour() bez hranové detekce


Obr. 7.12 zobrazuje použití přednastavené funkce užitím metody bez hran pro segmentaci chrupavky a detekci osteoartrózy. Inicializační masky byly pro účely porovnání použity totožné s přechozí metodou. Z pravého snímku je patrné, že detekce patologických změn se opět zdařila.

Při porovnání těchto dvou metod je zjevná vyšší efektivita metody bez hran, kdy nedochází natolik k přidružené segmentaci okolních tkání ani ke ztrátě obrazové informace ořezáváním chrupavky. Na druhou stranu musíme zvážit fakt, že použitím této metody lze segmentovat pouze všechny tři chrupavky najednou.

7.3.2 Testování na nativních snímcích

Tato část testování zahrnuje aplikaci metody aktivních kontur na nativní snímky. Inicializace počáteční kontury je u těchto snímků obtížnější, neboť chrupavka tvoří jen velmi malou část obrazu.

Nastavení parametrů: $\Delta t = 0,1$, $\varepsilon = 0,5$, $\sigma = 4$, $c_0 = 4$, $v = 0,0001 \times 255 \times 255$, $\mu = 1$, $n = 450-900$, $\lambda_1 = 0,85$, $\lambda_2 = 0,96$, $\alpha = 20$



Obr. 7.13 – Testování metody na nativních snímcích

Na Obr. 7.13 jsou v levém sloupci zobrazeny finální kontury v testovaných snímcích, v prostředním sloupci jsou umístěny barevné mapy a v pravém sloupci jsou umístěny binární zobrazení výsledné extrakce chrupavky.


Barevná mapa snímku je zobrazení výsledných intenzit bodů (rozložení energie) při evoluci kontury, kdy platí, že body uvnitř kontury mají zápornou hodnotu a body vně kladnou (viz kapitola 6.2 Geometrické aktivní kontury). Hodnoty pixelů jsou převedeny do barevné škály, kdy modrá barva značí záporné hodnoty a žlutá kladné hodnoty.

Pomocí barevné mapy lze potom prahováním extrahovat výsledný binární obraz, který zobrazuje segmentovanou oblast bílou barvou a její okolí černou barvou.

7.3.3 Testování na ROI

V tomto případě byla inicializace počáteční kontury snadnější a výpočetní náročnost programu daleko nižší.

Nastavení parametrů: $\Delta t = 0,02$, $\varepsilon = 0,5$, $\sigma = 4$, $c_0 = 4$, $v = 0,0001 \times 255 \times 255$, $\mu = 1$, $n = 450-900$, $\lambda_1 = 0,85$, $\lambda_2 = 0,96$, $\alpha = 20$



Obr. 7.14 – Testování metody na ROI

Stejně jako v předchozím případě je na Obr. 7.14 v levém sloupci znázorněna finální kontura, v prostředním sloupci je barevná mapa a v pravém sloupci extrahovaná chrupavka v binárním zobrazení.


Segmentace i detekce patologických změn proběhla u všech snímků rychle a úspěšně, jedinou nevýhodou u tohoto typu předzpracování je viditelná ostrost hran segmentovaného objektu, kdy může extrakcí této oblasti docházet ke ztrátě obrazové informace, a to v konečném důsledku může ovlivnit další výsledky (např. při volumetrických měřeních).

Jak je vidět na barvených mapách na Obr. 7.14, oblasti se stejnou hodnotou energie jsou charakterizovány většími body, a tedy i kontura má tendenci se pohybovat většími skoky. Proto je nutné u těchto snímků snížit délku časového kroku, aby se kontura nevychýlila mimo oblast chrupavky.

7.3.4 Testování na ROI s interpolací

Při testování těchto snímků bylo nutno zvýšit hodnotu délky časového kroku z důvodu vyššího počtu pixelů způsobené interpolací. Ze stejného důvodu se zvýšila i výpočetní náročnost, ale také kvalita segmentace.

Nastavení parametrů: $\Delta t = 0,8$, $\varepsilon = 1$, $\sigma = 15$, $c_0 = 4$, $v = 0,0006 \times 255 \times 255$, $\mu = 1$, $n = 100-500$, $\lambda_1 = 1,02$, $\lambda_2 = 1,2$, $\alpha = 20$



Obr. 7.15 – Testování metody na ROI s interpolací

Na Obr. 7.15 oproti Obr. 7.14 je viditelný rozdíl hran segmentovaného objektu na první pohled. Na snímcích po interpolaci jsou hrany více kontinuální a nedochází k jejich skokovým změnám v důsledku nízkého počtu obrazových bodů. Výsledná extrakce chrupavky je proto daleko přesnější a lze na ní snáze detekovat patologické změny.

7.3.5 Testování snímků s jasovou transformací


Při testování těchto dat vyšlo najevo, že navýšení rozdílu intenzit bodů u hrany segmentovaného objektu může mít kontraproduktivní účinek. V případě testovaných snímků jasová transformace segmentaci spíše zkomplikovala, a to jak výpočetní náročností, tak zhoršeným pohybem kontury směrem k záhybům a zúženým oblastem chrupavky.

K dosažení uspokojivých výsledků bylo potřeba rapidně zvýšit počet iteračních kroků, což negativně ovlivnilo výpočetní náročnost, která dosahovala oproti snímkům bez jasové transformace až dvojnásobných hodnot.

U ROI snímků bylo před jasovou transformací pro segmentaci v průměru použito 600 iteračních kroků, po jasové transformaci průměrný počet vzrostl na 916 iteračních kroků. U nativních snímků to bylo před jasovou transformací průměrně 533 iteračních kroků a po transformaci asi 866 kroků. U interpolovaných snímků bylo pro úspěšnou segmentaci nutno v průměru použít minimálně 264 iteračních kroků, po jasové transformaci až 425 iteračních kroků.

1) Nativní snímky


Nastavení parametrů: $\Delta t = 0,45$, $\varepsilon = 0,25$, $\sigma = 8$, $c_0 = 7$, $v = 0,0005 \times 255 \times 255$, $\mu = 1$, $n = 450-900$, $\lambda_1 = 0,85$, $\lambda_2 = 0,96$, $\alpha = 20$



Obr. 7.16 – Testování metody na nativních snímcích po jasové transformaci

2) ROI

Nastavení parametrů: $\Delta t = 0,035$, $\varepsilon = 0,25$, $\sigma = 8$, $c_0 = 7$, $v = 0,0005 \times 255 \times 255$, $\mu = 1$, $n = 450-900$, $\lambda_1 = 0,85$, $\lambda_2 = 0,96$, $\alpha = 20$




Obr. 7.17 – Testování metody na ROI po jasové transformaci

Z testování na nativních snímcích po jasové transformaci a ROI po jasové transformaci vyšlo najevo, že při zesílení bodů s vyšší jasovou intenzitou dochází také k zesílení artefaktů v obraze, a proto se kontura při své evoluci hůře rozpíná do nejasných okrajů chrupavky, jak je vidět na Obr. 7.16 a Obr. 7.17. Výsledná extrakce je proto neúplná, nicméně osteoartróza byla u těchto snímků opět úspěšně detekována.

3) ROI po interpolaci

Nastavení parametrů: $\Delta t = 0,15$, $\varepsilon = 0,1$, $\sigma = 15$, $c_0 = 7$, $v = 0,0009 \times 255 \times 255$, $\mu = 1$, $n = 100-500$, $\lambda_1 = 0,85$, $\lambda_2 = 0,98$, $\alpha = 20$



Obr. 7.18 – Testování metody na ROI po jasové transformaci a interpolaci


Podobně jako v předchozím případě dochází také k zesílení artefaktů a kontura není schopna detekovat okraj chrupavky. Kvalita segmentovaného obrazu je opět, co se týče hladkosti hran, vyšší, stejně jako u interpolovaných snímků bez jasové transformace.

7.3.6 Vliv umístění a tvaru inicializační kontury na segmentaci


1) Vliv umístění

Umístění inicializační kontury má při použití této metody značný vliv na výslednou segmentaci. V této fázi testování jsem se zabývala tím, které oblasti kolenního kloubu jsou pro umístění inicializační kontury nejvhodnější.

Na Obr. 7.19 je zobrazen případ nevhodného umístění. V této oblasti má chrupavka nejasnou hranici, a proto se kontura při své evoluci nemá „čeho přichytit“. Naopak na Obr. 7.20 je vidět příklad správného umístění kontury pro femorální i tibiální chrupavku. Lze z toho tedy vyvodit závěr, že pro umístění inicializační kontury je nejdůležitější zřetelná hranice chrupavky oproti okolním tkáním.



Obr. 7.19 – Nevhodné umístění inicializační kontury




Obr. 7.20 – Správně zvolené umístění inicializační kontury

2) Vliv tvaru a velikosti

Tvar inicializační kontury naopak neovlivňuje výsledek segmentace tolik, jako její umístění. Tvarem kontury můžeme pouze ovlivnit, jak rychle se kontura bude pohybovat v počátečních krocích, a tím podstatně urychlit celý proces. Na Obr. 7.21 je zobrazen výsledek segmentace při použití kružnice jako inicializační křivky. Při porovnání s výsledkem na Obr. 7.20 vidíme, že výsledek je téměř totožný.

Na velikosti kontury však záleží úspěšnost segmentace. Pokud zvolíme konturu příliš malou, dojde ke špatnému vyvážení energií a křivka se zmenšuje, dokud úplně nevymizí. Pokud naopak zvolíme příliš velkou, kontura může inklinovat k jiným strukturám v obrazu. Proto je důležité zvolit velikost tak akorát.



Obr. 7.21 – Segmentace chrupavky za použití inicializace kružnicí


Na Obr. 7.21 vidíme v prvním řádku příklad segmentace tibiální chrupavky při inicializaci kružnicí, v druhém řádku je znázorněna segmentace femorální chrupavky při inicializaci kružnicí.

7.3.7 Analýza výpočetní náročnosti funkce

Výpočetní náročnost je podstatná část analýzy k určení, která metoda předzpracování je nejvhodnější vzhledem k výsledkům segmentace a délce trvání. Kromě typu předzpracování výpočetní náročnost ovlivňuje počet iteračních kroků pohybu kontury. Proto je výhodné volit skutečně takový počet kroků, který je nezbytný pro námi požadovaný výsledek. Následující analýza provádí komparaci všech užitých kombinací předzpracování a byla provedena na stejném snímku.

Prvními testovanými byli nativní snímek a nativní snímek po jasové transformaci. U nativních snímků, abychom dosáhli alespoň přibližného výsledku, je minimum použitých iteračních kroků 450. Délka segmentace bez jasové transformace vychází na 19–39 s. U stejného snímku po jasové transformaci segmentace trvá 23–48 s.


Pro testování na Obr. 7.22 jsem použila snímek o velikosti 512x512 pixelů a inicializační křivku ve tvaru elipsy o délce hlavní poloosy $a = 10$ a délce vedlejší poloosy $b = 5$.



Obr. 7.22 – Závislost výpočetní náročnosti pro nativní snímky

Dalšími testovanými jsou ROI a ROI po jasové transformaci. Z důvodu podobnosti těchto snímků s nativními jsem minimum iteračních kroků opět stanovila na 450. Délka segmentace u ROI vychází 10–19,5 s a u ROI po jasové transformaci 13–26 s.


Pro testování na Obr. 7.23 jsem použila snímek o velikosti 217x329 pixelů a inicializační křivku ve tvaru elipsy o délce hlavní poloosy $a = 10$ a délce vedlejší poloosy $b = 5$.



Obr. 7.23 – Závislost výpočetní náročnosti pro ROI

Posledními testovanými jsou ROI po interpolaci a ROI po interpolaci a jasové transformaci. Tyto snímky jsou výpočetně nejnáročnější z důvodu jejich vyššího rozlišení. Jako dostačující minimum iteračních kroků jsem zvolila hodnotu 100. Snímek bez jasové transformace dosahuje délky trvání segmentace 18,5–97 s a po jasové transformaci segmentace trvá 37–91 s.

Pro testování na Obr. 7.24 jsem použila snímek o velikosti 651x987 pixelů a inicializační křivku ve tvaru elipsy o délce hlavní poloosy $a = 20$ a délce vedlejší poloosy $b = 10$.



Obr. 7.24 – Závislost výpočetní náročnosti pro ROI po interpolaci


Při porovnání všech tří grafů jsem došla k závěru, že obecně výpočetně náročnější jsou všechny snímky po jasové transformaci. Nejkratší dobu trvala segmentace z ROI obrazu, neboť má nejmenší počet pixelů, a nejdéle trvala segmentace u interpolovaných snímků z opačného důvodu.

Minimální počet iteračních kroků se u interpolovaných snímků liší z důvodu jejich vyššího rozlišení. Kontura se u těchto snímků nemá tendenci zachytávat na nežádoucích strukturách, a proto lze nastavit vyšší časový krok posunu křivky.


7.3.8 Testování algoritmu na jiných sekvencích

Pro experimentální účely testování algoritmu jsem zvolila sekvence rychlé spinové echo (T1 vážený obraz a proton-denzní obraz bez metody potlačení tuku) a 3D gradientní echo. Jedná se o snímky kolenní oblasti, ze kterých jsem pro zjednodušení segmentace vytvořila ROI zaměřené na oblast chrupavky.


Nastavení parametrů: $\Delta t = 0,02$, $\varepsilon = 0,5$, $\sigma = 4$, $c_0 = 4$, $v = 0,0001 \times 255 \times 255$, $\mu = 1$, $n = 450-900$, $\lambda_1 = 0,85$, $\lambda_2 = 0,96$, $\alpha = 20$



Obr. 7.25 – Testování metody na sekvenci rychlé spinové echo, T1 vážený obraz [8]



Obr. 7.26 – Testování metody na sekvenci 3D gradientní echo [12]




Obr. 7.27 – Testování metody na sekvenci rychlé spinové echo, proton-denzní obraz, bez potlačení tuku [8]

Jak je viditelné na obrázcích, extrakce chrupavky byla u všech tří obrazů úspěšná. Ani jedna z uvedených testovaných sekvencí nevyžaduje žádné mimořádné nastavení oproti snímkům z datasetu. Jediný značný rozdíl je v nutnosti navýšení počtu potřebných iteračních kroků, ale díky nízké výpočetní náročnosti na ROI obrazech má tato změna minimální vliv na délku segmentace.

8 Validace manuální segmentací

Extrahované oblasti, znázorňující chrupavku v bipolárním zobrazení, budou v této kapitole porovnány s oblastmi extrahovanými manuálně, a to porovnáním obsahů segmentovaných ploch v jednotkách pixelů.

Na Obr. 8.1 je znázorněn průběh manuální segmentace. Modré znaky označují jednotlivé body křivky obepínající oblast chrupavky. Pro účely co nejpřesnější segmentace byl snímek v softwaru několikrát přiblížen a byl umístěn co největší počet bodů, aby byl detekován každý záhyb chrupavky. Následně byla provedena extrakce označené oblasti převedením snímku na binární obraz a byl vypočten obsah segmentované části.



Obr. 8.1 – Průběh a výsledek manuální segmentace artikulární chrupavky

Na Obr. 8.2 je vlevo výstup modelu aktivních kontur, vpravo je znázorněna chrupavka segmentovaná manuálně. Na první pohled je viditelné, že manuálně segmentovaná chrupavka má větší délkový rozsah, kdežto chrupavka segmentovaná aktivními konturami je více zaoblená a do délky se moc nerozpíná. Podobné výsledky byly dosaženy u všech testovaných snímků.



Obr. 8.2 – Porovnání automatické (vlevo) a manuální (vpravo) segmentace artikulární chrupavky

Validace byla pro každý typ předzpracování provedena na pěti stejných snímcích z datasetu, přičemž pro každý snímek byly provedeny tři pokusy manuální segmentace (z důvodu eliminace nepřesností lidským faktorem). U každého pokusu byl vypočítán obsah extrahované části a následně byl vypočítán průměr a průměrný rozdíl od obsahu vypočítaného extrakcí aktivními konturami. Na závěr byl vypočítán z těchto průměrů procentuální rozdíl mezi těmito dvěma metodami. Tento rozdíl udává, jaká je nepřesnost segmentace aktivními konturami v procentech.

Tato kapitola porovnává nepřesnosti v segmentaci metodou aktivních kontur v závislosti na různých typech předzpracování obrazu.

8.1 Nativní snímky

Porovnání manuální segmentace a segmentace aktivními konturami u nativních snímků zobrazuje Tab. 1. Předpokládá se, že kvůli nízkému rozlišení snímků bude segmentace místy nepřesná, obzvláště v detailech, a proto bude i odchylka ploch nabývat vyšších hodnot.

Tab. 1 – Porovnání segmentovaných ploch chrupavek z nativních snímků

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|---------|-------------|----------------------------------|
| 1. | 256x256 | 154 | 1. | 136 | 18 | |
| | | | 2. | 141 | 13 | |
| | | | 3. | 145 | 9 | |
| | | | Průměr: | 140,667 | 13,333 | 9,479 |
| 2. | 256x256 | 150 | 1. | 155 | 5 | |
| | | | 2. | 163 | 13 | |
| | | | 3. | 162 | 12 | |
| | | | Průměr: | 160 | 10 | 6,25 |
| 3. | 256x256 | 122 | 1. | 139 | 17 | |
| | | | 2. | 136 | 14 | |
| | | | 3. | 142 | 20 | |
| | | | Průměr: | 139 | 17 | 12,230 |
| 4. | 256x256 | 142 | 1. | 171 | 29 | |
| | | | 2. | 165 | 23 | |
| | | | 3. | 164 | 22 | |
| | | | Průměr: | 166,667 | 24,667 | 14,8 |
| 5. | 256x256 | 152 | 1. | 174 | 22 | |
| | | | 2. | 181 | 29 | |
| | | | 3. | 177 | 25 | |
| | | | Průměr: | 177,333 | 25,333 | 14,286 |
| Průměrné hodnoty všech snímků: | | | | | 18,067 | 11,409 |

Všechny testované snímky měly v tomto případě stejné rozlišení, nicméně plocha chrupavky byla kvůli variabilitě snímků stejně pro každý případ odlišná. Průměrná odchylka segmentace aktivními konturami činí 18,067 pixelů a průměrný procentuální rozdíl je 11,409 %. Nejnižší rozdíl byl zaznamenán u druhého snímku, kde procentuální rozdíl činí 6,25 %, nejvyšší byl u čtvrtého snímku, kde rozdíl dosahuje hodnoty 14,8 %.

8.2 ROI

V této části kapitoly jsou porovnány manuální segmentace a segmentace aktivními konturami chrupavek z vytvořených ROI snímků. Předpokladem je, že průměrná odchylka a procentuální rozdíl budou nabývat podobných hodnot jako u testování nativních snímků.

Tab. 2 – Porovnání segmentovaných ploch chrupavek z ROI

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|---------|-------------|----------------------------------|
| 1. | 109x165 | 166 | 1. | 141 | 25 | |
| | | | 2. | 149 | 17 | |
| | | | 3. | 147 | 19 | |
| | | | Průměr: | 145,667 | 20,333 | 13,959 |
| 2. | 106x162 | 187 | 1. | 162 | 25 | |
| | | | 2. | 157 | 30 | |
| | | | 3. | 169 | 18 | |
| | | | Průměr: | 162,667 | 24,333 | 14,959 |
| 3. | 105x150 | 153 | 1. | 172 | 19 | |
| | | | 2. | 166 | 13 | |
| | | | 3. | 169 | 16 | |
| | | | Průměr: | 169 | 16 | 9,467 |
| 4. | 116x165 | 158 | 1. | 183 | 25 | |
| | | | 2. | 175 | 17 | |
| | | | 3. | 186 | 28 | |
| | | | Průměr: | 181,333 | 23,333 | 12,868 |
| 5. | 109x159 | 124 | 1. | 144 | 20 | |
| | | | 2. | 139 | 15 | |
| | | | 3. | 146 | 22 | |
| | | | Průměr: | 143 | 19 | 13,287 |
| Průměrné hodnoty všech snímků: | | | | | 20,6 | 12,908 |

Průměrná hodnota odchylky segmentovaných ploch je rovna 20,6 pixelům a průměrná hodnota rozdílu v procentech je 12,908 %, což jsou mírně vyšší hodnoty, než u nativních snímků. Nejnížší procentuální rozdíl byl zaznamenán u třetího snímku, kde nabývá hodnoty 9,467 % a nejvyšší rozdíl o hodnotě 14,959 % nastal u druhého snímku.

8.3 ROI po interpolaci

U této části testování jsou očekávány nejpřesnější výsledky segmentace aktivními konturami. Tabulka opět porovnává výsledky softwaru s výsledky manuální segmentací. Rozdíly v jednotkách pixelů dosahují vyšších hodnot, neboť i rozlišení snímku bylo interpolací zvětšeno. Při převedení rozdílu na procenta lze výsledky porovnat s ostatními typy předzpracování.

Tab. 3 – Porovnání segmentovaných ploch chrupavek z interpolovaných ROI

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|----------|-------------|----------------------------------|
| 1. | 281x426 | 1379 | 1. | 1471 | 92 | |
| | | | 2. | 1453 | 74 | |
| | | | 3. | 1467 | 88 | |
| | | | Průměr: | 1463,667 | 84,667 | 5,785 |
| 2. | 350x543 | 2071 | 1. | 2021 | 50 | |
| | | | 2. | 2041 | 30 | |
| | | | 3. | 2048 | 23 | |
| | | | Průměr: | 2036,667 | 34,333 | 1,686 |
| 3. | 350x543 | 1700 | 1. | 1827 | 127 | |
| | | | 2. | 1816 | 116 | |
| | | | 3. | 1813 | 113 | |
| | | | Průměr: | 1818,667 | 118,667 | 6,525 |
| 4. | 314x450 | 1674 | 1. | 1563 | 111 | |
| | | | 2. | 1598 | 76 | |
| | | | 3. | 1587 | 87 | |
| | | | Průměr: | 1582,667 | 91,333 | 5,771 |
| 5. | 324x516 | 1683 | 1. | 1744 | 61 | |
| | | | 2. | 1759 | 76 | |
| | | | 3. | 1736 | 53 | |
| | | | Průměr: | 1746,333 | 63,333 | 3,627 |
| Průměrné hodnoty všech snímků: | | | | | 78,467 | 4,679 |

Průměrný rozdíl mezi manuální a softwarovou segmentací činí 78,467 pixelů a průměrný rozdíl v procentech je roven 4,679 %, což je značně nižší hodnota oproti testování na nativních snímcích a na ROI. Nejvyšší hodnoty nepřesnosti bylo dosaženo u třetího snímku, kde procentuální rozdíl je roven 6,525 %, kdežto nejpřesnější byl software při segmentaci druhého snímku, kde bylo dosaženo pouze 1,686% rozdílu.

8.4 Snímky po jasové transformaci

V této fázi validace lze očekávat nejvyšší rozdílové hodnoty, a to kvůli zesílení artefaktů v obrazech v důsledku zvýšení jejich kontrastu, jak již bylo zmíněno v kapitole 7.3.5 Testování snímků s jasovou transformací.

8.4.1 Nativní snímky po jasové transformaci

U těchto snímků výsledek segmentace opět nejvíce ovlivňuje jejich malé rozlišení (nepřesnosti v detailech), nyní se přidaly také artefakty z jasové transformace, a tedy lze očekávat vyšší rozdílové hodnoty, než u validace nativních snímků (Tab. 1).

Tab. 4 – Porovnání segmentovaných ploch chrupavek z nativních snímků po jasové transformaci

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|---------|-------------|----------------------------------|
| 1. | 256x256 | 120 | 1. | 134 | 14 | |
| | | | 2. | 138 | 18 | |
| | | | 3. | 139 | 19 | |
| | | | Průměr: | 137 | 17 | 12,409 |
| 2. | 256x256 | 97 | 1. | 121 | 24 | |
| | | | 2. | 123 | 26 | |
| | | | 3. | 126 | 29 | |
| | | | Průměr: | 123,333 | 26,333 | 21,351 |
| 3. | 256x256 | 113 | 1. | 157 | 44 | |
| | | | 2. | 154 | 41 | |
| | | | 3. | 159 | 46 | |
| | | | Průměr: | 156,667 | 43,667 | 27,872 |
| 4. | 256x256 | 132 | 1. | 153 | 21 | |
| | | | 2. | 156 | 24 | |
| | | | 3. | 158 | 26 | |
| | | | Průměr: | 155,667 | 23,667 | 15,203 |
| 5. | 256x256 | 124 | 1. | 171 | 47 | |
| | | | 2. | 168 | 44 | |
| | | | 3. | 165 | 41 | |
| | | | Průměr: | 168 | 44 | 26,190 |
| Průměrné hodnoty všech snímků: | | | | | 30,933 | 20,605 |

Průměrná odchylka segmentovaných ploch je 30,933 pixelů a průměrný procentuální rozdíl je 20,605 %. Hodnoty jsou tedy značně vyšší, než u těchto snímků bez jasové transformace. Nejnižšího procentuálního rozdílu 12,409 % bylo dosaženo u prvního snímku, který se jako jediný z testovaných přiblížil hodnotám z Tab. 1. Naopak nejvyššího rozdílu 27,872 % dosáhl třetí snímek.

8.4.2 ROI po jasové transformaci

U těchto snímků jsou předpokládány podobné výsledky jako u nativních snímků po jasové transformaci. Hlavní rozdíl mezi těmito dvěma skupinami je snadnější inicializace počáteční křivky u ROI snímků pro uživatele při softwarové segmentaci. Naopak v porovnání se snímky ROI bez použití jasové transformace jsou u této skupiny očekávány horší výsledky.

Tab. 5 – Porovnání segmentovaných ploch chrupavek z ROI po jasové transformaci

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|---------|-------------|----------------------------------|
| 1. | 109x165 | 146 | 1. | 171 | 25 | |
| | | | 2. | 170 | 24 | |
| | | | 3. | 173 | 27 | |
| | | | Průměr: | 171,333 | 25,333 | 14,786 |
| 2. | 106x162 | 149 | 1. | 167 | 18 | |
| | | | 2. | 169 | 20 | |
| | | | 3. | 162 | 13 | |
| | | | Průměr: | 166 | 17 | 10,241 |
| 3. | 116x165 | 132 | 1. | 205 | 73 | |
| | | | 2. | 193 | 61 | |
| | | | 3. | 197 | 65 | |
| | | | Průměr: | 198,333 | 66,333 | 33,445 |
| 4. | 105x150 | 178 | 1. | 165 | 13 | |
| | | | 2. | 152 | 26 | |
| | | | 3. | 155 | 23 | |
| | | | Průměr: | 157,333 | 20,667 | 13,136 |
| 5. | 109x159 | 118 | 1. | 136 | 18 | |
| | | | 2. | 138 | 20 | |
| | | | 3. | 131 | 13 | |
| | | | Průměr: | 135 | 17 | 12,593 |
| Průměrné hodnoty všech snímků: | | | | | 29,267 | 16,84 |

Rozdíl plochy chrupavky segmentované aktivními konturami od chrupavky segmentované manuálně je u těchto testovaných snímků 29,267 pixelů a procentuální rozdíl je 16,84 %. Procentuální rozdíl je tedy mírně nižší, než v předchozím případě (Tab. 4), ale naopak je vyšší, oproti snímkům ROI bez použití jasové transformace (Tab. 2).

8.4.3 ROI po interpolaci a jasové transformaci

U těchto snímků lze očekávat kvalitnější detekci detailů u interpolovaných snímků (jako v případě Tab. 3), ale naopak také opět zhoršenou detekci okrajů chrupavky z důvodu artefaktů způsobených změnou kontrastu jako v předchozích dvou případech.


Tab. 6 – Porovnání segmentovaných ploch chrupavek z interpolovaných ROI po jasové transformaci

| Snímek | Rozlišení snímku [px] | Plocha chrupavky automatickou segmentací [px] | Plocha chrupavky manuální segmentací [px] | | Rozdíl [px] | Průměrný procentuální rozdíl [%] |
|--------------------------------|-----------------------|---|---|----------|-------------|----------------------------------|
| 1. | 350x543 | 1664 | 1. | 2141 | 477 | |
| | | | 2. | 2126 | 462 | |
| | | | 3. | 2169 | 505 | |
| | | | Průměr: | 2145,333 | 481,333 | 22,436 |
| 2. | 314x450 | 1983 | 1. | 1462 | 521 | |
| | | | 2. | 1514 | 469 | |
| | | | 3. | 1493 | 490 | |
| | | | Průměr: | 1489,667 | 493,333 | 33,117 |
| 3. | 317x486 | 1288 | 1. | 1444 | 156 | |
| | | | 2. | 1523 | 235 | |
| | | | 3. | 1495 | 207 | |
| | | | Průměr: | 1487,333 | 199,333 | 13,402 |
| 4. | 326x494 | 1192 | 1. | 1455 | 263 | |
| | | | 2. | 1478 | 286 | |
| | | | 3. | 1492 | 300 | |
| | | | Průměr: | 1475 | 283 | 19,186 |
| 5. | 327x477 | 1226 | 1. | 1595 | 369 | |
| | | | 2. | 1574 | 348 | |
| | | | 3. | 1598 | 372 | |
| | | | Průměr: | 1589 | 363 | 22,845 |
| Průměrné hodnoty všech snímků: | | | | | 364 | 22,197 |

Rozdíl v plochách extrahovaných chrupavek dosahuje oproti stejným snímkům bez jasové transformace zhruba čtyřnásobně vyšší hodnoty, a to 364 pixelů. Procentuální rozdíl je 22,197 % a je nejvyšší ze všech testovaných skupin. Nejhorší výsledek byl dosažen u snímku č. 2, kde byl téměř třetinový rozdíl mezi segmentací softwarem a manuální segmentací. Nejnižší rozdíl nastal u snímku č. 3 a nabývá hodnoty 13,402 %.

8.5 Shrnutí

V této kapitole práce jsem se zabývala validací metody aktivních kontur pomocí manuální segmentace, abych ověřila, nakolik je segmentace a následná extrakce artikulární chrupavky touto metodou úspěšná, a také abych zjistila, která metoda či kombinace metod předzpracování je nejvhodnější pro použití této poloautomatické segmentační metody. Výsledky jsem shrnula do histogramu na Obr. 8.3.



Obr. 8.3 – Průměrný procentuální rozdíl jednotlivých testovaných skupin

Z grafu lze vyčíst, že nejhorších výsledků dosáhla segmentace u snímků ROI po interpolaci a jasové transformaci, zatímco nejlepších výsledků bylo dosaženo pouze vytvořením oblasti zájmu a následným provedením interpolace. Dále je patrné viditelné zhoršení výsledků u všech testovaných skupin po provedení jasové transformace. Překvapivým výsledkem jsou horší výsledky u testovaných ROI snímků vedle původních nativních snímků.

Výsledky dosažené u interpolovaných ROI, tedy 4,679 %, jsou natolik uspokojující, že metoda aktivních kontur by v budoucnu mohla být využívána pro diagnostické účely v oblasti artikulárních kolenních chrupavek.

9 Závěr

Tato práce se zabývá metodikou segmentace a následné extrakce artikulárních chrupavek kolene, konkrétně zkoumá a hodnotí efektivitu použití poloautomatické segmentační metody aktivních kontur na snímky kolenní oblasti pořízené magnetickou rezonancí o síle 1,5 T.

Díličními cíli práce jsou: porovnání účinnosti základních metod předzpracování obrazu a jejich kombinací při použití metody aktivních kontur, měření časové náročnosti těchto metod i samotného segmentačního procesu pro různý počet iteračních kroků, porovnání naimplementované segmentační metody s metodou přednastavenou v prostředí MATLAB a zkouška metody na snímcích pořízených také jinými sekvencemi magnetické rezonance než jsou snímky z datasetu.

Všechny testované snímky z datasetu zobrazují kolenní oblast s femorální artikulární chrupavkou postiženou osteoartritickými změnami prvního stupně. Jedním z vedlejších úkolů práce bylo ověření, zda algoritmus dokáže tyto patologické změny úspěšně detekovat a lze jej tedy použít jako spolehlivou diagnostickou metodu. U všech testovaných snímků, nehledě na použitou metodu předzpracování, byla počínající osteoartróza úspěšně detekována.

Metody předzpracování obrazu byly použity tři: vytvoření oblasti zájmu (ROI), interpolace snímku a jasová transformace. Následně jsem pracovala s různými kombinacemi těchto metod, za účelem zhodnocení jejich efektivitu. Efektivitu jsem hodnotila na základě validace, provedené manuální segmentací oblasti chrupavky a vzájemném porovnání extrahovaných ploch. Z důvodu eliminace chyby lidským faktorem jsem manuální segmentaci prováděla u každého snímku třikrát a plochu extrahovanou automaticky jsem porovnávala s průměrem ploch těchto tří pokusů.

Dle výsledků testování a validace se jako nejefektivnější kombinace metod předzpracování jeví vytvoření oblasti zájmu a následná interpolace snímku. Naopak, nejhorších výsledků dosáhly všechny snímky, u kterých byla provedena jasová transformace. Lze z toho tedy vyvodit závěr, že jasová transformace není vhodnou metodou předzpracování obrazu při použití této segmentační metody. Výsledky všech testovaných kombinací jsou shrnuty v histogramu na Obr. 8.3.

Měření výpočetní náročnosti bylo prováděno funkcí v prostředí MATLAB. V části předzpracování výpočetní náročnost nejvíce ovlivní metoda interpolace. Závislost mezi zvoleným stupněm interpolace a časem výpočtu je téměř lineární. Pro jeden zvolený snímek jsem provedla měření délky výpočtu pro interpolační stupně 1–10 a vytvořila křivku závislosti. Konkrétní výsledky jsou uvedeny na Obr. 7.7. Při interpolaci snímků z datasetu jsem použila třetí stupeň kubického typu interpolace, který se jevil jako vhodný kompromis mezi rozlišením výstupního snímku a výpočetní náročností. V části segmentace výpočetní náročnost nejvíce ovlivňuje rozlišení snímku, ale také jeho vlastnosti. Opět jsem mezi sebou porovnávala jednotlivé skupiny snímků vzniklé předzpracováním. Z poznatků měření vyplývá, že obecně výpočetně náročnější při segmentaci byly všechny snímky po jasové transformaci. Nejkratší dobu segmentace jsem zaznamenala u ROI snímků, zhruba dvojnásobnou dobu trvala segmentace nativních snímků a nejdéle z důvodu vyššího rozlišení trvala segmentace u interpolovaných snímků.

Nejefektivnější metodou předzpracování snímku při segmentaci a extrakci femorální artikulární chrupavky kolene je tedy vytvoření oblasti zájmu a následně její interpolace, kde rozdíl automatické a manuální segmentace činí v průměru 4,679 %. Nicméně, při volbě této metody je nutno počítat s vyšší

výpočetní náročností, která může dosahovat délky trvání až dvou minut. Tato varianta je vhodná například pro budoucí volumetrická měření, kde je potřeba dosáhnout co nejpřesnějších výsledků. Při detekci patologických změn je možné použít pro výpočet pouze nativní snímky, popřípadě ROI snímky, což výrazně sníží výpočetní náročnost, viz Obr. 7.22 a Obr. 7.23. Naprosto nevhodnou metodou předzpracování obrazů pro segmentaci aktivními konturami je jasová transformace, u které je následná segmentace znatelně výpočetně náročnější a při použití této metody bylo dosaženo nejhorších výsledků.

MATLAB ve své knihovně obsahuje funkci aktivních kontur, u které lze nastavit několik parametrů pro získání uspokojivého výsledku. Ani po přizpůsobení parametrů snímkům z datasetu jsem však nebyla schopna dosáhnout stejně kvalitního výsledku, jako naimplementovanou funkcí. Jediné pozitivum této přednastavené funkce byla úspěšná detekce osteoartrózy.

Na závěr jsem se pokoušela metodu aktivních kontur aplikovat také na T1-vážené obrazy sekvence rychlé spinové echo, na proton-denzní obrazy stejné sekvence, kde není využito metody potlačení tuku a na sekvenci 3D gradientní echo. U všech experimentálně testovaných snímků jsem dosáhla uspokojivých výsledků, a proto jsem usoudila, že tato metoda má ještě mnoho otevřených možností.

Skrze tuto práci jsem dokázala, že metoda aktivních kontur je aplikovatelná na oblast artikulárních chrupavek a do budoucna může být využívána pro volumetrická měření chrupavek nebo například pro tvorbu 3D modelů.

Seznam literatury

- [1] ČIHÁK, Radomír. *Anatomie I*. Třetí, upravené a doplněné vydání. Ilustroval Ivan HELEKAL, ilustroval Jan KACVINSKÝ, ilustroval Stanislav MACHÁČEK. Praha: Grada, 2016. ISBN 978-80-247-3817-8.
- [2] Human anatomy: Anatomy of knee. *Amulyabharat.com* [online]. 2016 [cit. 2016-11-17]. Dostupné z: <http://www.amulyabharat.com/new-best-images-gallery-anatomy-of-knee/>
- [3] VIŠŇA, Petr a Radek HART. *Chrupavka kolena*. Praha: Maxdorf, 2006. ISBN 80-7345-084-4.
- [4] TEMENOFF, Johnna S a Antonios G MIKOS. Review: tissue engineering for regeneration of articular cartilage. *Biomaterials* [online]. 2000,**21**(5), 431-440 [cit. 2016-09-23]. DOI: 10.1016/S0142-9612(99)00213-6. ISSN 01429612. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0142961299002136>
- [5] JAMES C-B, UHL TL. A Review of Articular Cartilage Pathology and the Use of Glucosamine Sulfate. *Journal of Athletic Training*. 2001;**36**(4):413-419.
- [6] BHOSALE, A. M. a J. B. RICHARDSON. Articular cartilage: structure, injuries and review of management. *British Medical Bulletin* [online]. 2008, **87**(1), 77-95 [cit. 2016-09-23]. DOI: 10.1093/bmb/ldn025. ISSN 0007-1420. Dostupné z: <http://bmb.oxfordjournals.org/cgi/doi/10.1093/bmb/ldn025>
- [7] HORČIČKA, Vladko. Osteoartróza. *Interní medicína pro praxi*. 2004, **2004**(5), 238-243.
- [8] Chondromalacia grading. *Radiopaedia.org* [online]. 2016 [cit. 2016-11-20]. Dostupné z: <https://radiopaedia.org/articles/chondromalacia-grading>
- [9] Jak zobrazit hyalinní chrupavky. *Národní lékařská knihovna* [online]. Praha, 2004 [cit. 2016-09-27]. Dostupné z: <http://www.nlk.cz/publikace-nlk/referatove-vybery/radiodiagnostika/2004/jak-zobrazit-hyalinni-chrupavky>
- [10] ŠTOURAČOVÁ, Alena, Marek MECHL, Andrea ŠPRLÁKOVÁ-PUKOVÁ, Daniel SCHWARZ a Jan BURDA. Možnosti zobrazení artikulární chrupavky včetně volumetrických měření. *Česká radiologie*, Praha: Galén, 2011, roč. 65, č. 1, s. 61-69. ISSN 1210-7883.
- [11] CREMA, Michel D., Frank W. ROEMER, Monica D. MARRA, et al. Articular Cartilage in the Knee: Current MR Imaging Techniques and Applications in Clinical Practice and Research. *RadioGraphics* [online]. 2011, **31**(1), 37-61 [cit. 2016-09-23]. DOI: 10.1148/rg.311105084. ISSN 0271-5333. Dostupné z: <http://pubs.rsna.org/doi/10.1148/rg.311105084>
- [12] GOLD, Garry E., Christina A. CHEN, Seungbum KOO, Brian A. HARGREAVES a Neal K. BANGERTER. Recent Advances in MRI of Articular Cartilage. *American Journal of Roentgenology* [online]. 2009,**193**(3), 628-638 [cit. 2016-09-23]. DOI: 10.2214/AJR.09.3042. ISSN 0361-803x. Dostupné z: <http://www.ajronline.org/doi/abs/10.2214/AJR.09.3042>

- [13] MECHL, Marek, Jaroslav TINTĚRA a Jan ŽIŽKA. *Protokoly MR zobrazování*. Praha: Galén, c2014. ISBN 978-80-7492-109-4.
- [14] Magnetická rezonance - MRI - NMR. *Medicinman* [online]. 2010 [cit. 2016-09-24]. Dostupné z: http://medicinman.cz/?p=metody&p_sub=mr
- [15] SHINDLE, Michael K. Magnetic Resonance Imaging of Cartilage in the Athlete: Current Techniques and Spectrum of Disease. *The Journal of Bone and Joint Surgery (American)* [online]. 2006, **88**(suppl_4), 27- [cit. 2016-11-20]. DOI: 10.2106/JBJS.F.00614. ISSN 0021-9355. Dostupné z: <http://jbjs.org/cgi/doi/10.2106/JBJS.F.00614>
- [16] DAM, Erik B., Martin LILLHOLM, Joselene MARQUES a Mads NIELSEN. Automatic segmentation of high- and low-field knee MRIs using knee image quantification with data from the osteoarthritis initiative. *Journal of Medical Imaging* [online]. 2015, **2**(2), 024001- [cit. 2016-11-20]. DOI: 10.1117/1.JMI.2.2.024001. ISSN 2329-4302. Dostupné z: <http://medicalimaging.spiedigitallibrary.org/article.aspx?doi=10.1117/1.JMI.2.2.024001>
- [17] RYZHKOV, Maxim. *Knee Cartilage Segmentation Algorithms: a Critical Literature Review*. 2015. Master thesis. Universiteit Utrecht. Vedoucí práce Dr. K. L. Vincken.
- [18] DODIN, P, J PELLETTIER, J MARTEL-PELLETIER a F ABRAM. Automatic Human Knee Cartilage Segmentation From 3-D Magnetic Resonance Images. *IEEE Transactions on Biomedical Engineering* [online]. 2010, **57**(11), 2699-2711 [cit. 2016-11-14]. DOI: 10.1109/TBME.2010.2058112. ISSN 0018-9294. Dostupné z: <http://ieeexplore.ieee.org/document/5510111/>
- [19] FOLKESSON, Jenny, Erik B. DAM, Ole F. OLSEN, Paola C. PETTERSEN a Claus CHRISTIANSEN. Segmenting Articular Cartilage Automatically Using a Voxel Classification Approach. *IEEE Transactions on Medical Imaging* [online]. 2007, **26**(1), 106-115 [cit. 2016-11-14]. DOI: 10.1109/TMI.2006.886808. ISSN 0278-0062. Dostupné z: <http://ieeexplore.ieee.org/document/4039531/>
- [20] YIN YIN, XIANGMIN ZHANG, Rachel WILLIAMS, XIAODONG WU, Donald D ANDERSON a Milan SONKA. LOGISMOS—Layered Optimal Graph Image Segmentation of Multiple Objects and Surfaces: Cartilage Segmentation in the Knee Joint. *IEEE Transactions on Medical Imaging* [online]. 2010, **29**(12), 2023-2037 [cit. 2016-11-20]. DOI: 10.1109/TMI.2010.2058861. ISSN 0278-0062. Dostupné z: <http://ieeexplore.ieee.org/document/5512662/>
- [21] LEE, Soochahn, Sang Hyun PARK, Hackjoon SHIM, Il Dong YUN a Sang Uk LEE. Optimization of local shape and appearance probabilities for segmentation of knee cartilage in 3-D MR images. *Computer Vision and Image Understanding* [online]. 2011, **115**(12), 1710-1720 [cit. 2016-11-20]. DOI: 10.1016/j.cviu.2011.05.014. ISSN 10773142. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1077314211001639>
- [22] DUPUY, Damian E., Robert M. SPILLANE, Michael S. ROSOL, Daniel I. ROSENTHAL, William E. PALMER, Dennis W. BURKE a Andrew E. ROSENBERG. Quantification of articular cartilage in the knee with three-dimensional MR imaging. *Academic Radiology* [online].

- 1996, **3**(11), 919-924 [cit. 2016-11-14]. DOI: 10.1016/S1076-6332(96)80299-6. ISSN 10766332. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1076633296802996>
- [23] GRAU, V., A.U.J. MEWES, M. ALCANIZ, R. KIKINIS a S.K. WARFIELD. Improved Watershed Transform for Medical Image Segmentation Using Prior Information. *IEEE Transactions on Medical Imaging*[online]. 2004, **23**(4), 447-458 [cit. 2016-11-14]. DOI: 10.1109/TMI.2004.824224. ISSN 0278-0062. Dostupné z: <http://ieeexplore.ieee.org/document/1281998/>
- [24] AKHTAR, S., C.L. POH a R.I. KITNEY. An MRI derived articular cartilage visualization framework. *Osteoarthritis and Cartilage* [online]. 2007, **15**(9), 1070-1085 [cit. 2016-11-14]. DOI: 10.1016/j.joca.2007.03.009. ISSN 10634584. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1063458407001136>
- [25] DURYEA, J., G. NEUMANN, M.H. BREM, et al. Novel fast semi-automated software to segment cartilage for knee MR acquisitions. *Osteoarthritis and Cartilage* [online]. 2007, **15**(5), 487-492 [cit. 2016-11-14]. DOI: 10.1016/j.joca.2006.11.002. ISSN 10634584. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1063458406003219>
- [26] GOUGOUTAS, Alexander J., Andrew J. WHEATON, Arijitt BORTHAKUR, Erik M. SHAPIRO, J. Bruce KNEELAND, Jayaram K. UDUPA a Ravinder REDDY. Cartilage volume quantification via Live Wire segmentation1. *Academic Radiology* [online]. 2004, **11**(12), 1389-1395 [cit. 2016-11-14]. DOI: 10.1016/j.acra.2004.09.003. ISSN 10766332. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1076633204005471>
- [27] KAUFFMANN, C., P. GRAVEL, B. GODBOUT, et al. Computer-aided method for quantification of cartilage thickness and volume changes using mri: validation study using a synthetic model. *IEEE Transactions on Biomedical Engineering* [online]. 2003, **50**(8), 978-988 [cit. 2016-11-14]. DOI: 10.1109/TBME.2003.814539. ISSN 0018-9294. Dostupné z: <http://ieeexplore.ieee.org/document/1213850/>
- [28] KASS, Michael, Andrew WITKIN a Demetri TERZOPOULOS. Snakes: Active contour models. *International Journal of Computer Vision*[online]. 1988, **1**(4), 321-331 [cit. 2016-10-15]. DOI: 10.1007/BF00133570. ISSN 0920-5691. Dostupné z: <http://link.springer.com/10.1007/BF00133570>
- [29] HUDEČEK, Tomáš. *Rozpoznávání objektů na snímcích v medicíně*. Ostrava, 2013. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava. Vedoucí práce Doc. Ing. Lačezar Ličev, CSc.
- [30] TOMEČEK, Jan. *Analýza medicínských snímků za účelem rekonstrukce objektu na snímku k následnému zpracování*. Ostrava, 2013. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava. Vedoucí práce Doc. Ing. Lačezar Ličev, CSc.
- [31] VESE, Luminita A.; CHAN, Tony F. A multiphase level set framework for image segmentation using the Mumford and Shah model. *International journal of computer vision*, 2002, **50**.3: 271-293.

- [32] VÁCLAVÍK, Jan. *Interpolace obrazů*. Brno, 2010. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Doc. Ing. RADIM KOLÁŘ, Ph.D.
- [33] WANG, Li, Lei HE, Arabinda MISHRA a Chunming LI. Active contours driven by local Gaussian distribution fitting energy. *Signal Processing* [online]. 2009, **89**(12), 2435-2447 [cit. 2017-03-02]. DOI: 10.1016/j.sigpro.2009.03.014. ISSN 01651684. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0165168409000942>
- [34] LI, Chunming, Chenyang XU, CHANGFENG Gui and M. D. Fox, "Level set evolution without re-initialization: a new variational formulation," *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2005, pp. 430-436 vol. 1. DOI: 10.1109/CVPR.2005.213. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1467299&isnumber=31472>
- [35] LI, Chunming, C. Y. KAO, J. C. Gore and Z. Ding, "Minimization of Region-Scalable Fitting Energy for Image Segmentation," in *IEEE Transactions on Image Processing*, vol. 17, no. 10, pp. 1940-1949, Oct. 2008. DOI: 10.1109/TIP.2008.2002304. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4623242&isnumber=4623174>

Seznam příloh

Příloha I CD (ukázky kódu, testovací snímky)